

Rafael Genés Durán
Carla Brugulat Rica
Juan Hernández Serrano
Oscar Esparza Martín
(Eds.)



XI Jornadas Nacionales de Investigación en Ciberseguridad

Barcelona, del 6 al 8 de mayo de 2026



Rafael Genés Durán · Carla Brugulat Rica · Juan Hernández Serrano · Oscar Esparza
Martín (Eds.)

Actas de las XI Jornadas Nacionales de Investigación en Ciberseguridad

XI Jornadas Nacionales de Investigación en
Ciberseguridad, JNIC 2026.

Barcelona, del 6 al 8 de mayo de 2026



iniciativa
digital politècnica
Publicacions Acadèmiques de la UPC

Editores

Rafael Genés Durán
Universitat Politècnica de Catalunya

Carla Brugulat Rica
Universitat Politècnica de Catalunya

Juan Hernández Serrano
Universitat Politècnica de Catalunya


Oscar Esparza Martín
Universitat Politècnica de Catalunya

ISBN: 979-13-88098-43-7

Primera Edición, mayo 2026

© Universitat Politècnica de Catalunya

Nota: Este documento toma como referencia las actas de
JNIC 2025, disponibles [aquí](#).



Esta obra se encuentra bajo una licencia Creative Commons CC BY-NC 4.0. Está permitida cualquier forma de copia, reproducción y redistribución del material de esta obra en cualquier medio o formato, pero no se permite un uso comercial de la obra original ni la generación de obras derivadas. Puede acceder al texto completo de la licencia en el siguiente enlace: <https://creativecommons.org/licenses/by-nc/4.0/deed.es>

Patrocinadores

Patrocinador Diamante



Somos el motor de la transformación tecnológica del grupo CaixaBank.
Desarrollamos soluciones financieras end to end con un claro objetivo:
reinventar las reglas de juego a nivel tecnológico de una forma inteligente,
flexible y con un impacto real en la sociedad.

Patrocinadores Oro



Patrocinadores Plata



Comités de programa

Comité de programa de investigación

Presidentes

Cristina Alcaraz Tello Universidad de Málaga
Juan Hernández Serrano Universitat Politècnica de Catalunya

Comité

Agustín Martín Muñoz	Institute of Physical and Information Technologies, Spanish National Research Council
Pino Caballero-Gil	Universidad de La Laguna
Andrés Caro	Universidad de Extremadura
Javier Carrillo-Mondéjar	Universidad de Zaragoza
Vanesa Daza	Universitat Pompeu Fabra
José María de Fuentes	Universidad Carlos III de Madrid
Jesús Díaz-Verdejo	Universidad de Granada
Santiago Escobar	Universitat Politècnica de València
Josep Lluís Ferrer Gomila	Universitat de les Illes Balears
Joaquín García-Alfaro	Institut Polytechnique de Paris
David García Rosado	Universidad de Castilla-La Mancha
Luis Javier García Villalba	Universidad Complutense de Madrid
Manuel Gil Pérez	Universidad de Murcia
Lorena González Manzano	Universidad Carlos III de Madrid
Luis Hernández Encinas	Institute of Physical and Information Technologies, Spanish National Research Council
Jordi Herrera-Joancomarti	Universitat Autònoma de Barcelona
Javier López	Universidad de Málaga
José Luis Martínez	Universidad de Castilla-La Mancha
Gregorio Martínez Pérez	Universidad de Murcia
David Megías	Universitat Oberta de Catalunya
Pantaleone Nespoli	Faculty of Computer Science, Universidad de Murcia
Luis Panizo	Universidad de León
Aljosa Pasic	Eviden
Magdalena Payeras-Capellà	Universidad de las Islas Baleares
Razvan Raducu	Universidad de Zaragoza
Helena Rifà-Pous	Universitat Oberta de Catalunya
Ricardo J. Rodríguez	Universidad de Zaragoza
M.C. Romero-Ternero	Universidad de Sevilla
Sergio Ruiz	Universidad de Castilla La-Mancha
Luis Enrique Sánchez Crespo	Universidad de Castilla-la Mancha
José Carlos Sancho Núñez	Universidad de Extremadura

Francesc Sebé	Universitat de Lleida
Ángel Jesús Varela Vaca	Universidad de Sevilla
Manuel Veiga	Universidad de Vigo
Víctor Villagrà	Universidad Politécnica de Madrid
José M. Vázquez-Naya	Universidade da Coruña
Urko Zurutuza Ortega	Mondragon Unibertsitatea

Comité del programa de transferencia

Presidentes

Vanesa Daza	Universidad Pompeu Fabra
Ana Ayerbe	TECNALIA
Juan González Martínez	Gradiant

Comité

David González	IKERLAN
Cristina Alcaraz	Universidad de Málaga
Eduardo Fernández Medina	Universidad de Castilla la Mancha
Raúl Orduna	VICOMTECH
Ángel López	ITCL
Francisco Benítez	FIDESOL
Juan Caubet	EURECAT
Juan Díez	INCIBE
Pino Caballero	Universidad de La Laguna
Ricardo J. Rodríguez	Universidad de Zaragoza
Rodrigo Díaz	I2CAT
Saioa Arrizabalaga	CEIT
Urko Zurutuza	Mondragon Unibertsitatea

Comité del programa de formación

Presidentes

Guiomar Corral Torruella	Universidad Ramon Llull
Olga León Abarca	Universitat Politècnica de Catalunya

Comité

Adriana Suárez Corona	Universidad de León
Ana Isabel González-Tablas	Universidad Carlos III de Madrid
María Teresa Gómez López	Universidad de Sevilla
Ángel Jesús Varela Vaca	Universidad de Sevilla
Antonio Robles Gómez	UNED
David García Rosado	Universidad de Castilla la Mancha
Iñaki Garitano Garitano	Mondragon Unibertsitatea
Isaac Agudo Ruiz	Universidad de Málaga
José Carlos Sancho Núñez	Universidad de Extremadura
Mar Ávila Vegas	Universidad de Extremadura
Maria Isabel Barceló Villanueva	Universitat de les Illes Balears
Maria Magdalena Payeras Capellà	Universitat de les Illes Balears
María de los Llanos Tobarra Abad	UNED
Noemi de Castro García	Universidad de León
Oscar Mogollón Gutiérrez	Universidad de Extremadura
Roberto Magán Carrión	Universidad de Granada
Victoria Alicia Marcos Sbarbaro	INCIBE
Xavier Larriva	Universidad Politécnica de Madrid
Yolanda Blanco Fernández	Universidad de Vigo

Comité de organización

Presidente

Óscar Esparza Martín Universitat Politècnica de Catalunya

Responsable de publicaciones

Rafael Genés Durán Universitat Politècnica de Catalunya

Miembros

Juan Hernández Serrano	Universitat Politècnica de Catalunya
Olga León Abarca	Universitat Politècnica de Catalunya
Rafael Genés Durán	Universitat Politècnica de Catalunya
Josep Peguerols Vallés	Universitat Politècnica de Catalunya
José L. Muñoz Tapia	Universitat Politècnica de Catalunya
Marcel Fernández Muñoz	Universitat Politècnica de Catalunya
Antonio Alarcón García-Saavedra	Universitat Politècnica de Catalunya
Carla Brugulat Rica	Universitat Politècnica de Catalunya
Israel Martín Escalona	Universitat Politècnica de Catalunya
Enrica Zola	Universitat Politècnica de Catalunya
Germán Saez Moreno	Universitat Politècnica de Catalunya
Isabel Martín	Universitat Politècnica de Catalunya
Javier Herranz Sotoca	Universitat Politècnica de Catalunya
Marc Guzmán Albiol	Universitat Politècnica de Catalunya
Víctor Rubio	Universitat Politècnica de Catalunya
Jordi Domenech	Universitat Politècnica de Catalunya
Marta Bellés Muñoz	Universitat Pompeu Fabra
Maria Bras Amorós	Universitat Politècnica de Catalunya

Comité de ejecutivo

Comité de ejecutivo

Miembros

Ana Fernandez	Universidad de Vigo
Ángel Jesús Varela	Universidad de Sevilla
Óscar Esparza Martín	Universitat Politècnica de Catalunya
Mar Ávila Vegas	Universidad de Extremadura
Juan González Martínez	Gradiant
Lorena González	Universidad Carlos III de Madrid
Manuel Gil Pérez	Universidad de Murcia
Oscar Lage Serrano	Tecnalia
Ricardo J. Rodríguez	Universidad de Zaragoza
Sheila Alonso Carrascal	INCIBE

Índice general

Conferencias invitadas	3
Aprendizaje automático e inferencia de conocimiento preservando la privacidad	3
La Confianza en Transición: Europa, Norteamérica y China en la Próxima Era Cibernética	5
Charla patrocinada	9
Cuando la confianza falla: IA, identidad y supply chain en banca	9
Programa científico	13
Sesión de Transferencia 1 - Detección avanzada, inteligencia y apoyo a la operación en ciberseguridad	13
Enrique Alegre, Eduardo Fidalgo, Laura Fernández-Robles, Manuel Castejón-Limas, Loya C. Haughton, Christopher Gaul, Waqar Tanveer, Milad Mirjalili	
LUCIA*: Plataforma de Transferencia Tecnológica para la Detección Multi-Amenaza y Protección Digital mediante IA * LUcha contra los Ciberdelitos aplicando Inteligencia Artificial: https://lucia.unileon.es	13
Diego Pérez-Vieites, Iván García-Nogueiras, Guillermo López-Pazos, Juan José Moreira-Pérez, Miguel Masciopinto, Paula Domínguez-Vázquez, Carmen García-Nogueiras	
VeraQuo: Plataforma multimodal para detección y trazabilidad de contenido sintético	18
Alejandro David Cayuela Tudela, Alejandro Buitrago López, Belén Cuesta Bartolomé, Teresa García de Alcaraz Ruiz, Itandehui Gris Sánchez, Carlos Manchón Vállegas, Sandra Menasalvas Medina, Laura Méndez García, Gregorio Martínez Pérez, Frida Muñoz Plaza, José A. Ruipérez-Valiente, José Francisco Suárez Mulero, Juan Manuel Tejero, Javier Pastor-Galindo	
Cyber threat intelligence in the context of information warfare within the EUCINF project	22
Francisco Oliva Bermejo, Jorge Maestre Vidal	
ECYSAP EYE: From Cyber Situational Awareness to Mission-Centric Decision Support for Enhanced Cyberspace Operations Pantaleone Nespoli* , Daniel Díaz-López* , Sergio López Bernal* ,	26
Sesión de pósters 1	31
Fernando Román-García, Antonio Alarcón, Juan Hernández Serrano, Oscar Esparza, Juanjo Alins	
NoRDEx: Un protocolo descentralizado optimista de no repudio para intercambios de datos	31
Álvaro Navarro Martínez, Sara Nieves Matheu Garcia, Antonio Fernando Skarmeta Gómez	
Automated Hyperledger Fabric Deployment for Continuous Cybersecurity Certification	34
Pere Vidiella, Pere Tuset-Peiró, Josep Peguerols, Michael Pilgermann	
LLM-based Classification of CVEs for Vulnerability Analysis in Medical IT Systems	38
Mauro Clavijo-Herrera, Rolando Trujillo-Rasua, Carles Anglés-Tafalla	
Review of: Decentralizing Photo Forensics for Public and Verifiable Trust	42

Aitor Brazaola-Vicario, Oscar Lage	
Satellite-enabled extension of QKD Networks for operation in remote environments	44
Pedro Beltrán-López, Manuel Gil Pérez, Pantaleone Nespoli	
Desarrollo de un Simulador de Ciberengaño basado en Teoría de Juegos y el Marco MITRE Engage	48
Farzam Rezaei, Luis de Pedro, Iván González	
Does encryption actually provide privacy? A study of the CESNET-TLS-Year22 dataset	52
Antonio Peso, Carla Ràfols, Vanesa Daza	
Verifiable Batch Evaluation of Nonlinear Functions with High Precision for Machine Learning	56
Sesión de Investigación 1 - Detección, prevención y respuesta	61
Pedro Beltrán-López, Pantaleone Nespoli, Manuel Gil Pérez, Alberto Huertas Celdrán	
MadHoney: Señuelos Tóxicos para la Defensa Activa en el Aprendizaje Federado Descen- tralizado	61
Mohammadhossein Homaei, Agustín Di Bartolo, Alberto Lopez Trigo, Pablo García Rodríguez, Mar Avila	
Hybrid Physics-Informed Neural Network (PINN) for Stealthy FDI Detection	70
Carlos Mario Braga, Joaquin Sierra, Manuel A. Serrano, Eduardo Fernández-Medina	
De la detección al diagnóstico: interpretación estructural de rupturas ecosistémicas en ciberseguridad	78
Daniel Huici, Ricardo J. Rodríguez, Eduardo Mena	
A review of: “An Extensible and Scalable System for Hash Lookup and Approximate Similarity Search with Similarity Digest Algorithms”	86
Antonio Lara-Gutierrez, Carmen Fernandez-Gago, Jose A. Onieva	
HDDAF: Un Framework para la Detección y Adaptación de Drift en Sistemas de Detección de Amenazas Basados en Inteligencia Artificial	88
Daniel Quirumbay Yagual, Diego Fernández Iglesias, Francisco J. Nóvoa	
A Review of: “A Hybrid EFMS-KMeans and CNN-GRU Architecture for Anomaly Detection in Encrypted Network Traffic.”	90
Rubén Pérez-Jove, Cristian R. Munteanu, Julián Dorado, Alejandro Pazos, Jose Vázquez-Naya	
Revisiting Network Traffic Foundation Models: A Systematic Review	92
Sesión de Investigación 2 - IA, modelos de lenguaje y aprendizaje	95
Tamim Al Mahmud, Najeeb Jebreel, Josep Domingo-Ferrer, David Sánchez	
DP2Unlearning: An Efficient and Guaranteed Unlearning Framework for Large Language Models	95
Loya C. Haughton, Eduardo Fidalgo, Victor González-Castro, Laura Fernández-Robles	
Breadth Over Depth: Why Domain Specialisation Without Multilingual Pretraining Fails for Bilingual Cybersecurity NER	98
Pedro Vidal-Balboa	
Un Marco Unificado de Aprendizaje Profundo Multicabeza para la Detección del Ciberacoso Enrique García-Arias* , Antonio Robles-Gómez* , Rafael Pastor-Vargas* , Llanos Tobarra* ,	106
Fernando Jesús García-Molina, Roberto Magán-Carrión, Antonio Ropa Muñoz	
¿Son capaces los Grandes Modelos de Lenguaje de comprender eventos de seguridad?	114
Tomás Pelayo-Benedet, Carlos H. Gañán	
Una revisión de “The Machines are Watching: Exploring the Potential of Large Language Models for Detecting Algorithmically Generated Domains”	122
Ángel Luis Perales Gómez, Lorenzo Fernández Maimó	
A Review of ShaTS: A Shapley-based Explainability Method for Time Series Artificial Intelligence Models	124
Ángel Luis Perales Gómez, Lorenzo Fernández Maimó	
Propuesta de un módulo de xAI con degradación controlada para frameworks de AD	126

Sesión de pósters 2	135
Sergio Ruiz-Villafranca, José Roldán-Gómez, Javier Carrillo-Mondéjar	
Arquitectura Adaptativa de IDS Federado para la Mitigación de Amenazas mediante Aprendizaje Semisupervisado en redes IoT/IIoT altamente heterogéneas	135
David Montoro Aguilera, Alejandro Buitrago López, Javier Pastor-Galindo, José A. Ruipérez-Valiente	
Simulating cyber influence operations in synthetic online social networks	140
Jordi Doménech, Olga León, Isabel V. Martín-Faus, Josep Peguerols	
Evaluación de la robustez de algoritmos de Machine Learning frente a ataques de envenenamiento de etiquetas en entornos IoMT	144
Joaquín Gaspar Medina-Arco, Roberto Magán-Carrión, Rafael A. Rodríguez-Gómez	
Applicability of adversarial attacks in machine learning based NIDSs: A preliminary analysis	148
Nora M. Villanueva, Marta Sestelo	
A Review of: Advanced detection of suspicious activity within UEBA framework using Deep Autoencoders	152
Xabier Sáez de Cámara, Irune Agirre, Pablo Valle, Aitor Arrieta, Mondragon Unibertsitatea	
Caracterización de Ataques Imperceptibles en Vision-Language-Action Models	154
Valentine Machaka, Saioa Arrizabalaga, Josune Hernantes	
A Review of: “Automated Moving Target Defence in OT Security: Dynamic IP-enabled VLAN and Port Shuffling.”	158
Mario Gutiérrez Delgado, Carmen Sánchez-Zas, Sonia Solera-Cotanilla, Xavier Larriva-Novo	
Metodología para la caracterización y modelado de la propagación de riesgos de ciberseguridad	160
Sesión de Transferencia 2 - Arquitecturas de confianza, identidad y protección de infraestructuras	165
Marc Romeu Casas	
Entropía Cuántica Verificable en Infraestructuras PKI: Integración de un Generador Cuántico de Números Aleatorios (QRNG) en LamassuIoT	165
Carles Anglés-Tafalla, Josep M. Gastó, Jordi Castellà-Roca, Alexandre Viejo, Fundació URV	
TrustDrive: Blockchain-Powered Driving Evidence Generation System	170
Mohammadhossein Homaei, Pablo García Rodríguez, Andrés Caro, Mar Ávila, Mehran Tarif	
Causal Digital Twins for Cyber-Physical Security in Water Systems: A Framework for Robust Anomaly Detection	174
Vicente Muñoz, Angel Pérez del Pozo, Claudio Soriente	
Self-Sovereign Digital Identity: a construction from Barreto et al. ID-based signatures . . .	176
Sesión de Investigación 3 - Escenarios y plataformas I	181
Daniel Muñoz Heredia, Diana Borrego, Ángel Jesús Varela-Vaca	
Optimising secure and sustainable smart home configurations	181
Javier Matanza, Lukas Sigrist, Jose Luis Rueda Torres, Gregorio López López	
MaDIoT 3.0: Análisis de Ataques a la Demanda y Generación Distribuida en un Sistema Eléctrico	184
José L. Ruiz-Catalán, Ángel Suárez-Bárcena, Antonio Santos-Olmo, Luis E. Sánchez, David G. Rosado, Eduardo Fernández-Medina	
Evaluando Riesgos de Ciberseguridad en Infraestructuras Distribuidas. El patrón MARISMA-DS	186
Javier Parada, Mario Reyes, Javier Lopez, Centre Tecnològic de Catalunya	
Emulación Adversaria Adaptativa aplicada a Infraestructuras Críticas y Redes IIoT	194
Carlos Riggio Diéguez, Araceli Goiriz Seoane	
Análisis comparativo de técnicas de engaño en OT: Honeypots Modbus deterministas vs. generativo basado en LLM	196
Sesión de pósters 3	205

Alexia Casado-González, Ángel Manuel Guerrero-Higueras, Vicente Matellán-Olivera	
Diseño conceptual de un marco de seguridad poscuántica para sistemas ciberfísicos	205
Albert Borràs Rius	
Riesgos Informacionales y Geopolíticos de la Cumbre Iberoamericana de Madrid 2026	210
Francisco J. Nóvoa, Daniel Garabato, Álvaro Sarmiento, Mario Casado, Ignasi de José, Carlos Dafonte	
Plataforma escalable de autenticación continua basada en biometría del comportamiento y modelos de inteligencia artificial	214
Belén Sánchez Pardo, Jaime Pujante Sáez, Ignacio Ruiz Chicano, José Luis Hernández Ramos	
Metataxonomía del factor humano en ciberseguridad alineada con estándares	216
Farid Bagheri-Gisour Marandyn, Néstor Rodríguez Pérez, Álvaro Jesús López López, Juan Atanasio Carrasco Mateos, Agustín Valencia Gil-Ortega, Javier Jarauta Sánchez, Rafael Palacios, José Antonio Rodríguez Mondéjar, Gregorio López López	
Desafíos de la Ciberseguridad OT en la Era NIS2: Amenazas, IA y Brechas de Implementación	220
E. Fernández-Morales, A. Robles-Gómez, R. Pastor-Vargas, R. Hernández, J. Sarrapia	
IA explicable (XAI) para la detección de ataques orientada a aplicaciones IoT rurales inteligentes	224
Vicente Mayor, Rafael Estepa, Antonio Estepa, Javier Muñoz-Calle	
Detección de anomalías temporales en accesos para sistemas UEBA	226
Sesión de Investigación 4 - Escenarios y plataformas II	231
Mohammadhossein Homaei, Inda Kreso, Óscar Mogollón Gutiérrez, Alberto López Trigo, Andrés Caro	
Quantitative Cyber-Physical Risk Assessment using Co-Simulation	231
Valentine Machaka, Saioa Arrizabalaga, Santiago Figueroa-Lorenzo, Josune Hernantes	
A Review of: “Assessing the impact of Modbus/TCP protocol attacks on Critical Infrastructure: WWTP case study.”	240
DiegoF BustamanteV, Luis E. Sánchez, David G. Rosado, Antonio Santos-Olmo, Eduardo Fernández-Medina, Jose L. Ruiz-Catalán	
Towards a sustainable cybersecurity framework for Agriculture 4.0 based on a systematic analysis of proposals	242
Daniel Foronda-Pascual, Carmen Camara, Pedro Peris-Lopez	
A summary of Untouchable and Cancelable Biometrics: Human Identification Using Radar-Based Heart Signals	244
Mohammadhossein Homaei, Alberto López, Andrés Caro, Mar Ávila	
Arquitectura de comando y control basada en roles para la orquestación segura de nodos de auditoría distribuidos	246
Sesión de Investigación 5 - Privacidad	255
Alejandro Pérez-Fuente, Pablo A. Criado-Lozano	
Evaluación de la Lealtad en Apps de Salud: Un Análisis de Discrepancias Mediante Ontologías	255
Andrea Jimenez-Berenguel, Marta Moure-Garrido, Celeste Campo, Carlos Garcia-Rubio	
Evaluation of DNS Traffic Obfuscation Strategies for Defending Against Mobile User Profiling	264
Josep Domingo-Ferrer	
How Worrying Are Privacy Attacks Against Machine Learning?	272
Unai Laskurain, Aitor Aguirre-Ortuzar, Urko Zurutuza, Mondragon Unibertsitatea	
A summary of: Privacy-Preserving Feature Valuation in Vertical Federated Learning Using Shapley-CMI and PSI Permutation	274
Jan Aguiló Plana, Vanesa Daza, Carrer de Roc Boronat	
Zaguik: Zero-Knowledge Attestation for Privacy-Preserving LLM Governance	276
Acumulación Ponderada, Marta Bellés-Muñoz	
Comparadores Eficientes en R1CS Mediante	283

Sesión de pósters 4	285
Javier Junquera-Sánchez	
Sistema de esteganografía coverless en audio basado en generación musical	285
Rafael Palacios Hielscher, Gregorio López López	
Detección automática de audio generado por Inteligencia Artificial	290
David Melendi, Xabiel G. Pañeda, Víctor Corcoba, Roberto García	
Métodos de detección e investigación forense de amenazas de insiders en contextos corpora- tivos: Un meta-estudio	294
Marcos Rodríguez Vega, Pino Caballero-Gil	
De Insultos a Identificadores: Enmascaramiento con LLMs y Aumento de Datos Iterativo para la Detección de Discurso de Odio Multiclase	298
Irene Gosálvez White, Pedro García Teodoro	
Benchmark experimental para estimar el nivel de seguridad de LLM con capacidades agénticas	302
Joana Justo Guillaumet, Alan Briones Delgado, Guiomar Corral Torruella	
Diseño e Implementación de un Next Generation Security Operations Center Basado en Herramientas Open Source e Integración de Inteligencia Artificial	306
Eva Manzano Caro, Fernando Broncano Morgado, Pablo Fernández González, Mar Ávila Vegas	
Análisis comparativo de sistemas de verificación de voz basados en inteligencia artificial . .	310
Marina Buitrago-Pérez, Georgia Zaharia, Jose Maria de Fuentes, Lorena Gonzalez-Manzano, Nicolas Anciaux	
Consistency is all you need – on the alignment between the EU AI Act and technical attacks against LLMs	314
Sesión de Investigación 6 - Blockchain, sistemas distribuidos e identidad soberana	319
Joan Ferré-Queralt, Jordi Castellà-Roca, Alexandre Viejo	
Predicción de Carga Segura y Privada en Smart Grids mediante Incentivos Basados en Blockchain	319
Iñaki Seco Aguirre, Cristina Regueiro Senderos, Borja Urquizu Gómez, Eduardo Jacob Taquet, Plaza Ingeniero Torres	
Protocolo Basado en FHE para la Caracterización Privada de Datos en Ecosistemas SSI .	322
Jaume Costa-Calvoparra, Jordi Herrera-Joancomartí	
How AI Agents Construct Privacy-Preserving Bitcoin Transactions	330
Sergi Morales Duque, Julián Salas Piñón	
Evaluating the Impact of a Cryptographically Relevant Quantum Computer on Bitcoin . .	338
Andreu Cecilia, Ramon Costa-Castelló	
Un protocolo de enmascaramiento para algoritmos de consenso no lineales e incremental- mente pasivos	344
Sesión de Formación 1 - Formación y concienciación en ciberseguridad	347
Xabiel G. Pañeda, David Melendi, Roberto García, Víctor Corcoba, Antonio Estepa	
Concienciación con casos reales: Importancia de una trazabilidad adecuada en el contexto de la PYME	347
Marco López, José Carlos Ramírez, Isaac Agudo	
Educating for Impact: A Strategic Vision for Ethereum Security Training	353
Andrea Baños Ramos, Mario Castro Ponce, Farid Bagheri-Gisour Marandyn, Constança Brito, Filipe Rodrigues, Gregorio López López	
Ciberdelitos entre niños y adolescentes en Portugal: un estudio basado en datos del videojuego RAYUELA	360
Marc Ruiz, Fernando Agraz	
Innovación en la Enseñanza de la Gestión de la Ciberseguridad en Estudios de Grado Universitario	368

Germán Sáez Moreno	
Tocando la criptografía: comprender la clave privada con una Máquina Enigma de cartón .	376
Sesión de Investigación 7 - Software y sistemas para la ciberseguridad	381
Martíño Rivera-Dourado, Christos Xenakis, Alejandro Pazos, Jose Vázquez-Naya	
A Review of EAP-FIDO: A Novel EAP Method for Using FIDO2 Credentials for Network Authentication	381
Jorge Garcia-Diaz, Daniel Escanez-Exposito, Pino Caballero-Gil	
qcrypto: Librería para la Simulación y Desarrollo de Protocolos Criptográficos Cuánticos .	384
Javier Pallarés de Bonrostro, Ana I. González-Tablas	
PQCryptoRefactorer: Pipeline verificado para migración poscuántica asistida por LLMs en repositorios reales	392
Antton Rodriguez, Xabier Etxezarreta, Iñaki Garitano, Mikel Iturbe, Urko Zurutuza, Mondragon Unibertsitatea, E- Arrasate-Mondragón	
MASTER-OF-PUPPETS: Framework Agentless de Control Remoto para Operaciones de Ciberseguridad	400
Anonymous Author(s)	
(Work in Progress): Towards Automated Phishing Kit Fingerprint Generation for Phishing Detection and Classification	408
Mohammadhossein Homaei, Agustín Di Bartolo, Óscar Mogollón-Gutiérrez, Pablo García Rodríguez, Andres Caro	
Process-Aware High-Interaction Honeypot using Shadow Digital Twins	414
Sesión de pósters 5	423
Miguel Gómez Carpena, Jorge Lanza, Luis Sánchez	
Gestión segura y descentralizada de DID Documents on-chain en Ethereum	423
Carlos Jimeno Miguel, Raúl Orduna Urrutia, Francesco Zola	
Identificación y anonimización de entidades nombradas en fuentes de información no estructurada para su uso en detección de ingeniería social	428
Ines Ortega-Fernandez	
On the Practical Viability of Local Agentic Language Models for Android Security Analysis	432
Víctor-Pablo Prado-Sánchez, Adrián Domínguez-Díaz, Luis De-Marcos, José-Javier Martínez-Herráiz	
A Review Of: Zero-Shot Classification of Illicit Dark Web Content with Commercial LLMs: A Comparative Study on Accuracy, Human Consistency, and Inter-Model Agreement . . .	436
Asier Gamba, Unai Rioja, Igor Armendariz, Durba Chatterjee, Lejla Batina	
Hacia detectores adaptativos: Transfer Learning en detección de Ataques de Fallos de Tensión	438
Jovan A. Guillén-Mass, Roberto Magán-Carrión	
A Purdue-Aligned Evaluation Framework and Reference Architecture for ICS Cybersecurity Testbeds	442
Lluís Bermúdez, Montserrat Guillen, Pau Nerín	
Prediction of hourly cyber support helpline request volume for real-time alerting systems .	446
Nil Ortiz Rabella, Albert Calvo Ibañez, Muhammad Shuaib Siddiqui	
Threat Mutation Identification via Transformer-based Analysis of Malware Assembly Code	450
Sesión de Investigación 8 - Criptografía	455
Arturo Hernández-Sánchez, Santiago Escobar	
A Symbolic Analysis of Hash Functions Vulnerabilities in Maude-NPA	455
Daniel Escanez-Exposito, Pino Caballero-Gil	
Simulación cuántica de lógica booleana, circuitos digitales y esquemas criptográficos	458
Iván Blanco Chacón	
A generalized approach towards root-based attacks against PLWE instances	460

Santiago Escobar, Kazuhiro Ogata	
Formalization and analysis of the post-quantum signature scheme FALCON with Maude	462
Jesús E. Díaz-Verdejo, Rafael Estepa, Antonio Estepa, Fco. Javier Muñoz-Calle, Germán Madinabeitia	
Una revisión de: Building a large, realistic and labeled URI dataset for website modelling in anomaly-based intrusion detection systems: Biblio-US17	464
Sesión de Formación 2 - Plataformas y entornos prácticos de aprendizaje	467
Joaquín Sierra Granados, Eugenio Romero Ciudad, Antonio Santos-Olmo, José Luis Ruíz Catalán, Ángel Suárez-Bárcena, Eduardo Fernández-Medina Patón	
Laboratorio docente de ciberseguridad: diseño, instrumentación y despliegue para prácticas y retos técnicos	467
Carlos Jimeno Miguel, Mikel Izal Azcárate	
CTF como Servicio: Una infraestructura reproducible y escalable para la formación en ciberseguridad	476
Julia Sánchez, José-María Romero, Alan Briones, Guiomar Corral	
Marco para el diseño y certificación de formación en ciberseguridad alineada con el ECSF mediante Cyber Ranges y entornos virtuales de aprendizaje	482
Diego Cabuya-Padilla	
MARCIM-WG: A wargame proposal based on math modeling applied in a naval scenario	484
Vanesa Daza, Carla Ràfols, Roc Boronat	
alicIA: Un asistente docente basado en GPT personalizado con enfoque socrático para la enseñanza de criptografía	492
Premios RENIC a la mejor tesis doctoral y al mejor trabajo fin de máster	503
Premio al mejor trabajo fin de máster	503
Daniel Blanco Aza	
Evaluación Exhaustiva de Riesgos de Privacidad Basada en IA en Aplicaciones Móviles y Redes Sociales	503
Premio a la mejor tesis doctoral	513
Luis Ibáñez Lissen	
Trusted AI techniques for cybersecurity applications	513
Índice de Autores	523

Conferencias invitadas

Aprendizaje automático e inferencia de conocimiento preservando la privacidad

Ponente: Dr. Vicenç Torra, Universidad de Umeå



Resumen

Vicenç nos explica los últimos resultados del grupo Nausica: PrivAcy-AWAre traNSparent deCIIsions group de la Universidad de Umeå, que investiga en el área de la privacidad para aprendizaje automático y estadística. En los últimos años han trabajado con varios modelos de privacidad (k-anonimidad, privacidad diferencial, privacidad integral), tipos de escenarios (centralizados y distribuidos – federated learning), y tipos de datos (bases de datos estándar, grafos, series temporales en smart grid). Actualmente trabajamos también en otros aspectos de seguridad para IA, en particular maneras de mitigar ataques de envenenamiento de memoria (memory poisoning). Por ejemplo, tenemos resultados sobre recuperación de conocimiento e inferencia lógica preservando la privacidad. En esta charla se presentarán algunos de nuestros resultados recientes.

Torra, V., Bras-Amorós, M. (2026) Memory poisoning and secure multi-agent systems <https://arxiv.org/abs/2603.20357> Varshney, A. K., Torra, V. (2025) Efficient federated unlearning under plausible deniability. Mach. Learn. 114(1): 25 (2025) <https://doi.org/10.1007/s10994-024-06685-x>

Biografía

Vicenç Torra es catedrático de IA en la Universidad de Umeå (Suecia) y es fellow del IEEE y de EurAI, así como ISI elected member. Ha sido catedrático en las Universidades de Maynooth (Irlanda) y Skövde (Suecia) y ha ocupado posiciones en el IIIA-CSIC y en la Universidad Rovira y Virgili. Su investigación se centra en los temas de privacidad de datos para aprendizaje automático y estadística y también en razonamiento aproximado (conjuntos difusos, medidas e integrales difusas, métodos de toma de decisiones). Ha escrito varios libros. Entre ellos "Modeling Decisions"(con Y. Narukawa, Springer, 2007), "Data Privacy"(Springer, 2017), "Guide to Data Privacy"(Springer, 2022). Es fundador y editor de la revista Transactions on Data Privacy. Desde el año 2004 organiza la conferencia anual Modeling Decisions for Artificial Intelligence.

La Confianza en Transición: Europa, Norteamérica y China en la Próxima Era Cibernética

Wei Yuan Mao, Director Operaciones, Cybersecurity BU, Applus+ Laboratories



Resumen

La ciberseguridad ha dejado de ser una cuestión de protección técnica para convertirse en un factor de poder económico, liderazgo tecnológico e influencia geopolítica. Sus fundamentos están cambiando simultáneamente en dos frentes. En el plano geopolítico, las premisas que sostuvieron la confianza digital global —estándares convergentes, certificación interoperable y marcos de evaluación compartidos— se están fragmentando. La desacoplación estratégica entre Estados Unidos, Europa y China está dando lugar a tres modelos de confianza incompatibles: orientado a la innovación, a la regulación y a la soberanía. En el plano tecnológico, la IA redefine el equilibrio entre ataque y defensa, la criptografía poscuántica impone una migración ineludible y la identidad digital se consolida como infraestructura soberana, con la Cartera Europea de Identidad Digital (EUDIW) como caso clave. Esta ponencia propone entender la ciberseguridad como una disciplina de gestión de transiciones. Basada en quince años de experiencia en evaluación de seguridad europea, trabajo asesor en ENISA y participación directa en la revisión de la arquitectura EUDIW, se dirige a la comunidad JNIC: la investigación en verificación formal, identidad y privacidad es el cimiento de la próxima infraestructura de soberanía digital. El desafío urgente es cerrar la brecha entre excelencia científica y ejecución industrial evaluada y escalable.

Biografía

Wei Yuan Mao es Director de Operaciones de la Unidad de Ciberseguridad de Applus+ Laboratories. Con más de quince años de experiencia en evaluaciones ITSEF (Common Criteria hasta EAL6+, EMVCo, SESIP y GSMA), es Experto designado por ENISA en la EUDIW y especialista en Common Criteria. Su trabajo se centra en la regulación europea de la evaluación de seguridad, la criptografía poscuántica y la identidad digital. Es Executive MBA por ESADE y MSc en Seguridad de la Información.

Charla patrocinada

Cuando la confianza falla: IA, identidad y supply chain en banca

Joan Reigidor Sanfeliu, CaixaBank Tech



Resumen

La charla aborda vectores emergentes en ciberseguridad bancaria como ataques a la cadena de suministro (supply chain), compromiso de identidad (phishing avanzado y bypass de MFA) y nuevas superficies derivadas del uso de LLMs (prompt injection y exfiltración de datos). A partir de casos reales y tendencias emergentes, se exploran los riesgos actuales y cómo evolucionará la ciberseguridad financiera en un entorno donde el atacante también se apoya en sistemas inteligentes.

Biografía

Joan es un apasionado de la ciberseguridad con más de 10 años de experiencia en distintos ámbitos dentro de este campo. A lo largo de su trayectoria ha trabajado en diversas áreas del espectro de la seguridad, lo que le ha permitido desarrollar una visión global y práctica frente a los retos actuales. Actualmente compagina su actividad profesional en el sector con una participación activa en la comunidad de ciberseguridad, asistiendo a conferencias especializadas y manteniéndose al día de las últimas tendencias y amenazas. Además, participa regularmente en competiciones de tipo Capture The Flag (CTF), donde pone a prueba y perfecciona sus habilidades técnicas en entornos prácticos y desafiantes. Su enfoque combina la experiencia profesional con una clara vocación por el aprendizaje continuo y la mejora constante.

Programa científico

Sesión de Transferencia 1 - Detección avanzada, inteligencia y apoyo a la operación en ciberseguridad

LUCIA*: Plataforma de Transferencia Tecnológica para la Detección Multi-Amenaza y Protección Digital mediante IA

*LUcha contra los Ciberdelitos aplicando Inteligencia Artificial: <https://lucia.unileon.es>

Aitor Del Río Ferreras, Enrique Alegre, Eduardo Fidalgo, Víctor González-Castro, Rocío Alaiz-Rodríguez, Laura Fernández-Robles, Manuel Castejón-Limas, Alicia Martínez-Mendoza, Loya C. Haughton, Christopher Gaul, Waqar Tanveer, Milad Mirjalili

Grupo de Visión y Sistemas Inteligentes (GVIS)

IA Institute, Universidad de León, León, España

{ariof, ealeg, efidf, vgonc, ralar, lferr, mcasl, amartm, lhau, cgau, wtan, mmir}@unileon.es

Resumen—El incremento y sofisticación de las amenazas digitales —smishing, phishing y delitos de explotación— exigen herramientas de detección integrales y operativas. En este trabajo se presenta LUCIA, un demostrador de tecnologías de Inteligencia Artificial fruto de la colaboración entre INCIBE y la Universidad de León. La plataforma actúa como nexo entre investigación y aplicación práctica, integrando capacidades de Procesamiento del Lenguaje Natural y Visión por Computador para la detección de amenazas, análisis forense y protección de colectivos vulnerables. La arquitectura, basada en microservicios y alineada con el Esquema Nacional de Seguridad (ENS), garantiza la soberanía del dato y la seguridad mediante control de acceso por roles y auditoría. Resultados operativos demuestran latencias de 0,02 s en smishing y validación en TRL 7, consolidando a LUCIA como un asistente versátil, preparado tanto para el apoyo técnico en centros de respuesta a incidentes (CERT) como para la consulta directa por parte del usuario final en la prevención de ciberestafas.

Index Terms—Inteligencia Artificial, Ciberseguridad, Transferencia Tecnológica, ENS, Protección de Menores.

I. INTRODUCCIÓN

En el contexto actual, los ataques digitales han evolucionado desde incidentes aislados hasta constituir un problema estructural de seguridad que afecta a ciudadanos, empresas e instituciones. Amenazas como el *smishing* [1], el fraude en comercio electrónico [2] o el *grooming* [3] presentan una creciente sofisticación y diversidad, explotando tanto vulnerabilidades técnicas como patrones de uso inadecuados de las tecnologías. Esta complejidad limita la eficacia de soluciones tradicionales basadas en reglas estáticas y exige enfoques más adaptativos y escalables.

La Inteligencia Artificial (IA) se perfila como un elemento clave para el análisis automatizado de grandes volúmenes de información y el apoyo operativo a equipos CERT y organismos similares [4]. No obstante, su impacto real depende de su integración en entornos operacionales y de una colaboración efectiva entre investigación académica y organismos públicos. En este marco, la cooperación entre el Grupo de Visión y

Sistemas Inteligentes (GVIS)¹ de la Universidad de León y el Instituto Nacional de Ciberseguridad (INCIBE)² ejemplifica un modelo de alineación entre capacidades investigadoras y necesidades estratégicas nacionales.

Con este objetivo surge **LUCIA**, una plataforma de transferencia tecnológica que integra múltiples capacidades de detección de ciberamenazas en una interfaz unificada. El presente trabajo describe la integración operacional de modelos avanzados de IA en un entorno real alineado con el Esquema Nacional de Seguridad (ENS), validado en colaboración con INCIBE y desplegado mediante una arquitectura segura basada en microservicios.

II. CONTEXTO DEL PROYECTO Y OBJETIVOS DE TRANSFERENCIA

La plataforma LUCIA (Fig. 1), disponible en <https://lucia.unileon.es/>, es el resultado de un proyecto estratégico de Investigación y Desarrollo desarrollado en el marco de la colaboración entre el grupo GVIS de la Universidad de León e INCIBE, que actúa como agente promotor y facilitador de la transferencia. Esta colaboración ha permitido orientar la investigación hacia necesidades reales del sector y facilitar la transferencia de resultados, superando la fase de prueba de concepto para ofrecer un entorno funcional que refuerza las capacidades nacionales de respuesta ante incidentes.

Sus objetivos principales son:

- **Consolidación de capacidades de IA:** Integrar diversos modelos de aprendizaje profundo (PLN y Visión Artificial) en una solución unificada, eliminando la dispersión de herramientas característica de los entornos de investigación.
- **Accesibilidad y explicabilidad:** Proporcionar una interfaz de alta usabilidad que, además de ser accesible, ofrece explicaciones de los motivos de la detección y

¹<https://gvis.unileon.es/>

²<https://www.incibe.es/>



Figura 1: Pantalla de inicio e interfaz unificada de LUCIA.

sugerencias de buenas prácticas para prevenir futuros casos de smishing entre otros tipos de ciber-fraudes.

- **Plataforma demostradora:** Funcionar como un entorno tecnológico modular y extensible, orientado a futuras líneas de investigación y al despliegue de nuevos módulos para abordar un mayor número de ciberdelitos.

III. ARQUITECTURA Y FUNCIONALIDADES

III-A. Visión general y diseño modular

LUCIA es una plataforma web integradora, compuesta por un frontend y servicios de apoyo, junto con módulos de análisis desplegados en contenedores Docker, diseñada para reunir distintas herramientas de detección en un mismo entorno. Todas las herramientas integradas, desarrolladas durante el proyecto estratégico financiado por INCIBE, operan como componentes independientes, lo que permite actualizar modelos o añadir nuevas funcionalidades sin afectar al resto del sistema.

La plataforma es multilingüe (inglés y castellano) y se ha diseñado para simplificar el uso de técnicas de Inteligencia Artificial mediante una interfaz accesible, facilitando el trabajo de equipos de ciberseguridad, CERTs y otros organismos especializados, así como la protección de usuarios no especializados frente a amenazas digitales. LUCIA integra once módulos especializados, desde detección de amenazas en comunicaciones (email, SMS, chat) hasta protección de datos personales y colectivos (p.ej. menores de edad), cuyas entradas y salidas se resumen en la Tabla I.

Tabla I: Módulos de la plataforma LUCIA: entradas y salidas

Módulo	Entrada (Individual / Lote)	Salida / Resultado
Smishing	Texto SMS / Captura de pantalla	Riesgo, Categoría y Similitud
Spam	Archivo .eml, .txt	Tipología, Riesgo y Malware
Ciberincidentes	Texto descriptivo / Archivos .txt	Resumen, Taxonomía e IoCs
E-Commerce	URL / JSON (HTML, SSL, Tech)	Fraude, Whois y Geoposición
Clasif. Menores	Imagen (JPG, PNG) / Rostros	Edad estimada y Estadísticas
Estima. Edad	Imagen (Rostro oculto)	Reconstrucción y Edad
CSAM	Imagen (JPG, JPEG, PNG)	Detección y Pixelado auto.
Grooming	Chat (TXT, JSON, XML)	Tácticas y Análisis semántico
Phishing	URL / Código HTML	Probabilidad y Redirecciones
Anonimización	Texto plano / Excel, CSV	Tokenización y Enmascarado

III-B. Especificaciones técnicas y modelos

LUCIA se fundamenta en arquitecturas de aprendizaje profundo de última generación. En el ámbito del PLN, la

plataforma utiliza modelos basados en *Transformers* [8], como *DistilBERT* [9], *ALBERT* [10], *RoBERTa* [11] y *SecureBERT* [12], centrados en la comprensión y representación contextual del lenguaje, que permiten tareas como clasificación semántica multilingüe y reconocimiento de entidades para la anonimización.

Asimismo, se integran modelos de lenguaje de gran escala (LLMs) como *Llama 3.2 (3B)* para análisis contextuales profundos, apoyándose en conjuntos de datos especializados de ciberseguridad creados durante el proyecto LUCIA en el grupo GVIS, como *MIMICS-3500*, *CECILIA*, *SERC-4K* y *SPEMC-15K APD*, accesibles en la página web del grupo GVIS³.

En visión artificial y análisis forense, LUCIA implementa *Vision Transformers (ViT)* [13] y modelos de detección en tiempo real como *YOLOv12n-face* [15], junto con técnicas de reconstrucción facial y estimación biométrica mediante *SwinFace* [16]. La detección de amenazas web se refuerza con modelos específicos como *Opara* [14] y el uso de datasets masivos como *PILWD-134K*.

III-C. Seguridad y gestión operativa

El sistema implementa una arquitectura de microservicios orquestada con *Docker*, donde el núcleo de la interfaz y el proxy inverso (*Nginx*) gestionan el tráfico externo. La seguridad perimetral se refuerza con un WAF (*ModSecurity*) y *Fail2ban*, que analizan los registros del frontend para detectar intentos de ataque.

La plataforma implementa un sistema de gestión de usuarios basado en roles (modelo RBAC), que:

- protege las credenciales mediante *bcrypt* con *salt*, con opción de autenticación de doble factor (2FA);
- permite a los administradores gestionar el ciclo de vida de los usuarios, asignar privilegios por módulo y desactivar funcionalidades temporalmente según necesidades de mantenimiento o seguridad;
- genera registros de actividad desde cada contenedor, integrados con los logs de *FastAPI* y *Gunicorn*, para garantizar trazabilidad de las peticiones y el rendimiento de los modelos.

III-D. Especificaciones de hardware

LUCIA se ejecuta sobre una infraestructura de alto rendimiento equipada con aceleración gráfica mediante GPUs de gama profesional, lo que permite ejecutar eficientemente modelos basados en Vision Transformers y LLMs, garantizando una inferencia fluida incluso en escenarios de alta demanda computacional.

IV. ENFOQUE METODOLÓGICO Y USO DE IA

Uno de los objetivos de LUCIA es proporcionar una herramienta eficiente para escenarios operativos reales, seleccionando la tecnología más adecuada a cada tipo de problema y asegurando que la información recibida por el analista sea útil, clara y fácilmente interpretable.

³https://gvis.unileon.es/datasets_main/

IV-A. Estrategias de aprendizaje y lógica de procesamiento

La plataforma adopta un enfoque híbrido que integra distintas estrategias de aprendizaje en un flujo de procesamiento unificado, estructurado en tres ejes:

- **Preprocesamiento y aprendizaje automático tradicional:** Se aplica un triaje inicial mediante extracción de características y filtrado heurístico, con OCR para la interpretación de texto en capturas de pantalla y mecanismos de enriquecimiento externo (e.g., consultas WHOIS), que optimizan recursos y aportan contexto al análisis.
- **Visión Artificial basada en Transformers:** Para el análisis de imágenes (p.ej. contenido sensible o estimación de edad), se emplean Vision Transformers (ViT) que capturan dependencias globales y patrones complejos; en escenarios con oclusiones, se utilizan procedimientos de reconstrucción facial para mejorar la robustez.
- **Análisis contextual mediante NLP y LLMs:** En el ámbito textual, se combinan técnicas de Procesamiento del Lenguaje Natural con LLMs como Llama 3.2 (3B), que identifican patrones semánticos y señales de manipulación psicológica (como en *grooming*). El sistema incorpora técnicas de IA explicable (XAI) que, en el caso de smishing y *grooming*, proporcionan al analista un resumen de las razones de la detección (p.ej., señales de urgencia, presión emocional o patrones de lenguaje sospechosos).

IV-B. Privacidad, ética y seguridad

Durante el desarrollo, se han aplicado mecanismos de privacidad sobre los datos procesados, como el pixelado automático en el módulo de detección de contenido sensible, diseñado para minimizar la exposición directa a material catalogado como “sensible”. El cumplimiento del Reglamento General de Protección de Datos (RGPD) [6] se garantiza mediante el módulo de anonimización, que aplica *hashing* y *masking* a la información de identificación personal.

La soberanía tecnológica se asegura mediante el despliegue en infraestructura propia; aunque se consulten APIs externas para metadatos (WHOIS), el procesamiento de datos sensibles y evidencias forenses se realiza exclusivamente en servidores locales basados en contenedores Docker con permisos restringidos, dentro del perímetro de seguridad requerido por el ENS [5].

V. EVIDENCIA DE TRANSFERENCIA Y VALIDACIÓN OPERACIONAL

La madurez tecnológica de LUCIA se sitúa en un estadio **TRL 7** [7] (Technology Readiness Level (Nivel de Madurez Tecnológica)), habiendo sido validada en un entorno operacional real mediante pruebas de carga y estrés. La evidencia de transferencia se materializa en la creación de LUCIA, una plataforma operativa completa que integra dicha tecnología en un entorno utilizable por analistas y organismos, transformando la capacidad de análisis de prototipos de investigación en un servicio desplegado y sostenible.

Como ejemplo de la eficiencia del sistema, la detección de amenazas en *smishing* presenta una latencia de apenas **0,02 s** con aceleración por GPU, manteniéndose en **0,08 s** en configuraciones de CPU. Por otro lado, las tareas de anonimización de evidencias se ejecutan en un rango de entre **0,1 y 1 segundo**.

VI. CASOS DE USO Y ESCENARIOS DE APLICACIÓN

Los siguientes escenarios se definieron junto con INCIBE como requisitos de aplicación de la plataforma y han servido para guiar su diseño. A la fecha de redacción del artículo, la última versión de LUCIA ha sido entregada y se encuentra pendiente de validación de aceptación por parte del usuario final.

1. **Investigación forense:** apoyo a la identificación de rangos de edad en imágenes con rostros ocluidos mediante el módulo de reconstrucción facial.
2. **Triage de smishing y spam masivo:** agrupación automática de reportes para clasificar en distintas categorías y producir estadísticas así como pertenencia a otras campañas, ilustrada en la Figura 2.




Figura 2: Interfaz de entrada de mensajes SMS para el triaje de smishing.

3. **Categorización de ciberincidentes:** clasificación automatizada según la taxonomía de INCIBE [17], extrayendo entidades e indicadores de compromiso, ilustrada en la Figura 3.




Figura 3: Interfaz de gestión y taxonomía de ciberincidentes.

VII. CONCLUSIONES Y TRABAJO FUTURO

La plataforma LUCIA representa un avance significativo en la integración de inteligencia artificial de vanguardia con las

necesidades operativas de la ciberseguridad nacional. Se ha demostrado que es posible integrar modelos complejos (*Deep Learning* y LLMs) en una arquitectura modular que prioriza la soberanía tecnológica, la accesibilidad para los analistas de CERT y la accesibilidad para el usuario final.

VII-A. Aportaciones y valor estratégico

La principal aportación de este trabajo es la creación de una plataforma que centraliza y racionaliza el uso de múltiples herramientas de análisis en un entorno unificado, accesible para equipos de ciberseguridad y ciudadanos, manteniendo la gestión de los datos en infraestructura propia alineada con el ENS. La integración de IA explicable en algunos módulos (como el análisis de smishing y *grooming*) complementa esta aportación, ya que permite mostrar al analista y, en cierta medida, al usuario final, las razones de las decisiones de detección, sin que supere la accesibilidad y la centralización como contribución principal.

- **Apoyo al Técnico (CERT/LEA):** LUCIA actúa como asistente avanzado para el analista, integrando la detección automatizada con información comprensible y resultados revisables, lo que agiliza la toma de decisiones críticas.
- **Seguridad y Autonomía del ciudadano:** La plataforma permite que un usuario sin conocimientos técnicos comprenda las razones básicas de la detección de una amenaza, fomentando una cultura de ciberseguridad basada en la comprensión y no solo en la alerta automatizada.

LUCIA valida que el despliegue de herramientas de IA éticas y operadas en infraestructuras locales bajo el estándar del ENS es un camino válido para fortalecer la resiliencia digital de las instituciones y la ciudadanía.

VII-B. Líneas de trabajo futuro

La evolución de la plataforma se orienta hacia el fortalecimiento de su explotación operativa (aproximando un TRL 9), la integración con ecosistemas de ciberseguridad existentes y la extensión de su uso a otros actores institucionales. En concreto, se plantean tres ejes:

- **Integración con servicios operativos:** Conexión con bases de datos de inteligencia de ciberamenazas (CTI) y otros sistemas de CERT para enriquecer automáticamente los informes de incidentes, sin que el sistema pierda la soberanía de los datos sensibles.
- **Análisis multimodal y nuevos módulos de análisis:** Ampliación del conjunto de módulos de análisis (por ejemplo, procesamiento de audio y vídeo) para abordar amenazas emergentes como *deepfakes*, aprovechando la arquitectura modular de LUCIA.
- **Escalado, accesibilidad y replicabilidad:** Optimización de la orquestación para despliegues nacionales de alta disponibilidad, simplificación de la interfaz orientada a usuarios no especializados y adaptación de la plataforma para que sea replicable en otros entornos de ciberseguridad (p.ej., otras administraciones públicas o organismos de respuesta).

En definitiva, LUCIA se postula como una solución robusta y replicable que pone la tecnología más avanzada al servicio de la seguridad colectiva, contribuyendo al fortalecimiento de un entorno digital más seguro.

REFERENCIAS

- [1] INCIBE, “¿Qué es el smishing?,” INCIBE, 2024. Disponible en: <https://www.incibe.es/ciudadania/formacion/recursosdescargables/ques-es-el-smishing>. Accedido el 10 de febrero de 2026
- [2] M. Sánchez-Paniagua, E. Fidalgo, E. Alegre y F. Jáñez-Martino, “Fraudulent E-Commerce Websites Detection Through Machine Learning,” in *International Conference on Hybrid Artificial Intelligence Systems*, pp. 267–279, 2021.
- [3] INCIBE, “Grooming,” INCIBE, 2024. Disponible en: <https://www.incibe.es/aprendeciberseguridad/grooming>. Accedido el 10 de febrero de 2026
- [4] CEOE, “Panorama actual sobre el impacto de la Inteligencia Artificial en la Ciberseguridad,” Informe Técnico, 2024. Accedido el 10 de febrero de 2026
- [5] CCN-CERT, “Normas de Seguridad en el ENS: Guía CCN-STIC 821,” Centro Criptológico Nacional, 2022. Accedido el 10 de febrero de 2026
- [6] Unión Europea, “Reglamento (UE) 2016/679 del Parlamento Europeo y del Consejo relativo a la protección de las personas físicas en lo que respecta al tratamiento de datos personales y a la libre circulación de estos datos (RGPD),” Diario Oficial de la Unión Europea, 2016. Accedido el 10 de febrero de 2026
- [7] Ministerio de Industria, Comercio y Turismo, “Notas sobre economía industrial,” Revista Economía Industrial, 2023. Accedido el 10 de febrero de 2026
- [8] G. Tuceanu, M. Bucos, B. Dragulescu y C. D. Căleanu, “Natural language processing with transformers: a review,” *PeerJ Comput. Sci.*, vol. 10, Art. no. e2222, 2024, doi: 10.7717/peerj-cs.2222.
- [9] V. Sanh, L. Debut, J. Chaumond y T. Wolf, “DistilBERT, a distilled version of BERT: smaller, faster, cheaper and lighter,” *arXiv:1910.01108*, 2019. Disponible en: <http://arxiv.org/abs/1910.01108>.
- [10] Z. Lan, M. Chen, S. Goodman, K. Gimpel, P. Sharma y R. Soricut, “ALBERT: A Lite BERT for Self-supervised Learning of Language Representations,” en *Proceedings of the International Conference on Learning Representations (ICLR)*, 2020. Disponible en: <https://openreview.net/pdf?id=H1eA7AEtvS>.
- [11] Y. Liu, M. Ott, N. Goyal, J. Du, M. Joshi, D. Chen, O. Levy, M. Lewis, L. Zettlemoyer y V. Stoyanov, “RoBERTa: A Robustly Optimized BERT Pretraining Approach,” *arXiv:1907.11692*, 2019. Disponible en: <http://arxiv.org/abs/1907.11692>.
- [12] E. Aghaei, S. Jain, P. Arun y A. Sambamoorthy, “SecureBERT 2.0: Advanced Language Model for Cybersecurity Intelligence,” *arXiv:2510.00240*, 2025. Disponible en: <https://arxiv.org/abs/2510.00240>.
- [13] A. Dosovitskiy, L. Beyer, A. Kolesnikov, D. Weissenborn, X. Zhai, T. Unterthiner, M. Dehghani, M. Minderer, G. Heigold, S. Gelly, J. Uszkoreit y N. Houlsby, “An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale,” en *Proceedings of the 9th International Conference on Learning Representations (ICLR)*, 2021. Disponible en: <https://openreview.net/forum?id=YicbFdNTTy>.
- [14] R. B. Basnet, A. H. Sung y Q. Liu, “OPARA: A Multi-Layered Approach for Phishing Detection,” en *Proc. IEEE 11th Int. Conf. on Machine Learning and Applications (ICMLA)*, pp. 358–363, 2012, doi: 10.1109/ICMLA.2012.63.
- [15] U. Aymon, N. S. Kamarudin y A. F. Ab. Nasir, “Facial Expression Recognition with YOLOv11 and YOLOv12: A Comparative Study,” en *Proc. ICSECS*, pp. 18–23, 2025. IEEE.
- [16] L. Qin, M. Wang, C. Deng, K. Wang, X. Chen, J. Hu y W. Deng, “SwinFace: A Multi-Task Transformer for Face Recognition, Expression Recognition, Age Estimation and Attribute Estimation,” *IEEE Trans. Circuits Syst. Video Technol.*, vol. 34, no. 4, pp. 2223–2234, Apr. 2024, doi: 10.1109/TCSVT.2023.3304724.
- [17] INCIBE-CERT, “Taxonomía de incidentes de ciberseguridad,” INCIBE, 2024. Disponible en: <https://www.incibe.es/incibe-cert/incidentes/taxonomia>. Accedido el 10 de febrero de 2026

VeraQuo: Plataforma multimodal para detección y trazabilidad de contenido sintético

Diego Pérez-Vieites, Iván García-Nogueiras, Guillermo López-Pazos, Juan José Moreira-Pérez,
Miguel Masciopinto, Paula Domínguez-Vázquez, Carmen García-Nogueiras
Gradient, Vigo, España
{dperez, igarcia, glpazos, jmoreira, mmasciopinto, pdvazquez, cgnogueiras}@gradient.org

Resumen—El uso malicioso de modelos de inteligencia artificial generativa ha incrementado la producción de contenido sintético altamente realista en formatos de texto, imagen, audio y vídeo, generando riesgos significativos en identidad digital, desinformación, fraude y análisis forense. Este trabajo presenta VeraQuo, una plataforma multimodal basada en IA que integra capacidades de detección y trazabilidad de contenido manipulado o generado artificialmente. La solución adopta una arquitectura modular basada en microservicios, diseñada para su integración flexible en entornos productivos heterogéneos y para su explotación en modalidad SaaS u on-premises.

El sistema ha sido desarrollado en el marco de una Compra Pública Precomercial y validado con usuarios finales de distintos sectores estratégicos. Los resultados evidencian su viabilidad operativa, resiliencia y capacidad de transferencia efectiva desde un entorno de investigación aplicada hacia aplicaciones reales en ciberseguridad y verificación digital.

Index Terms—IA, deepfakes, IA generativa, transferencia tecnológica, ciberseguridad

Tipo de contribución: *Transferencia*

I. INTRODUCCIÓN

El rápido avance de los modelos de inteligencia artificial generativa ha facilitado la creación automática de contenido sintético altamente realista en formatos de vídeo, imagen, audio y texto. En este trabajo, el término “contenido sintético” se emplea como concepto general que engloba tanto contenido completamente generado por IA como contenido manipulado. En la misma dirección, también han proliferado el número de herramientas de acceso público que permiten generar deepfakes faciales [2], entendidos aquí como técnicas de suplantación de identidad mediante manipulación facial en vídeo, clonación de voz con muestras reducidas o manipulaciones documentales prácticamente indistinguibles para un observador no experto. Esta evolución tecnológica, si bien abre nuevas oportunidades creativas y productivas, introduce riesgos significativos en múltiples sectores estratégicos.

Entre las principales amenazas se encuentran la suplantación de identidad en procesos de verificación digital, la manipulación de evidencias multimedia, la difusión de desinformación mediante contenidos audiovisuales generados artificialmente y los ataques de fraude apoyados en voz sintética, riesgos ampliamente documentados por organismos internacionales [7]. La creciente sofisticación de estos contenidos dificulta su detección manual y supera en muchos casos las capacidades de los mecanismos tradicionales de control [3]. El crecimiento del uso malicioso de contenidos sintéticos se recoge también en informes recientes de panorama de amenazas en ciberseguridad [8]. En consecuencia, existe una necesidad urgente de soluciones tecnológicas avanzadas que

permitan detectar, analizar y mitigar el impacto del contenido sintético en entornos operacionales reales.

Para dar respuesta a esta problemática se ha desarrollado VeraQuo, una plataforma multimodal basada en inteligencia artificial orientada a la detección y trazabilidad de contenido generado o manipulado mediante técnicas generativas. La solución ha sido concebida desde su origen con un enfoque de transferibilidad, priorizando su integración efectiva en procesos productivos y su adaptación a casos de uso reales en distintos sectores.

Desde el punto de vista técnico, VeraQuo se basa en una arquitectura modular compuesta por servicios especializados en el análisis de diferentes modalidades de contenido (vídeo, imagen, audio y texto). Estos servicios incorporan modelos de aprendizaje automático entrenados para identificar patrones asociados a generación sintética, manipulación digital y ataques de suplantación. La arquitectura adopta un enfoque basado en microservicios desplegables en contenedores, lo que permite su escalabilidad, interoperabilidad y despliegue tanto en modalidad SaaS como en entornos on-premises. Asimismo, la plataforma integra mecanismos de autenticación, control de accesos, cifrado en tránsito, trazabilidad de operaciones y monitorización operativa, garantizando su adecuación a entornos con requisitos exigentes de seguridad y confidencialidad.

El desarrollo de la plataforma se ha llevado a cabo en el marco del proyecto fAIR, enmarcado en el contexto de la cuarta Compra Pública Precomercial CPP001/24 financiado por la “Unión Europea NextGeneration-EU, Plan de Recuperación, Transformación y Resiliencia”, a través de INCIBE. El proyecto ha estado orientado desde sus fases iniciales a la validación en entornos reales y a la colaboración estrecha con usuarios finales de sectores como la verificación de identidad digital, la investigación policial, la verificación periodística y los sistemas de atención al cliente basados en voz.

II. CASOS DE USO

La validación de la plataforma VeraQuo se ha realizado en distintos contextos operacionales representativos, cubriendo sectores con requisitos funcionales y regulatorios diferenciados. A continuación se describen los principales casos de uso abordados.

Verificación de identidad digital: En procesos de onboarding remoto, las entidades financieras y proveedores de servicios digitales requieren validar la identidad de un usuario mediante la captura de documentos oficiales y biometría facial. La aparición de documentos manipulados digitalmente o imágenes generadas mediante inteligencia artificial supone un riesgo significativo para la integridad del proceso.

Detección de fraude por voz en contact centers: Los ataques de clonación de voz y replay representan una amenaza creciente en sistemas de autenticación telefónica y atención al cliente. La disponibilidad de herramientas de síntesis de voz permite suplantar identidades con un alto grado de realismo.

El principal reto en este caso de uso es equilibrar precisión y latencia, evitando tanto falsos positivos que impacten la experiencia de usuario como falsos negativos que comprometan la seguridad.

Análisis forense de evidencias multimedia: Las fuerzas y cuerpos de seguridad requieren herramientas que permitan analizar contenidos audiovisuales obtenidos en investigaciones relacionadas con suplantación, pornografía sintética, desinformación o extorsión. La capacidad de producir reportes estructurados y técnicamente fundamentados refuerza la robustez probatoria y facilita la incorporación de resultados en procedimientos judiciales.

Verificación de contenidos en medios y fact-checking: Los medios de comunicación y organizaciones de verificación enfrentan un volumen creciente de contenidos audiovisuales virales cuya autenticidad debe evaluarse rápidamente.

Detección de fraude en seguros: El sector asegurador enfrenta un incremento en reclamaciones fraudulentas apoyadas en contenido manipulado o generado artificialmente. Ejemplos incluyen fotografías alteradas de daños materiales, vídeos manipulados para exagerar siniestros o documentación digital modificada.

La aplicación de mecanismos de detección automática en fases tempranas del proceso de tramitación contribuye a reducir costes asociados al fraude, mejorar la eficiencia operativa y reforzar los mecanismos de control interno.

III. MARCO FUNCIONAL

El marco funcional adoptado en el desarrollo de VeraQuo se estructura en dos capacidades fundamentales que articulan el funcionamiento de la plataforma: detección y trazabilidad. Estas capacidades han sido diseñadas para los diferentes tipos de contenido (audio, imágenes, vídeo y texto) de forma modular pero interconectada, permitiendo su activación independiente o combinada en función del caso de uso y del entorno operativo.

III-A. Detección de contenido sintético y manipulado

La capacidad de detección constituye el núcleo técnico de la plataforma. Su objetivo es identificar indicios de generación sintética, manipulación digital o suplantación en distintas modalidades de contenido. Responde a la cuestión: **¿el contenido ha sido generado sintéticamente?**, y de ser así, **¿con qué herramienta?** (atribución). Un ejemplo del resultado del sistema de detección se muestra en la Figura 1, en este caso, para el análisis de un vídeo Deepfake.

Desde el punto de vista metodológico, la detección se basa en el uso de modelos de aprendizaje automático especializados por modalidad, siguiendo las líneas de investigación ampliamente descritas en la literatura reciente sobre creación y detección de deepfakes [4]:

- **Vídeo:** análisis de inconsistencias espaciales y temporales asociadas a deepfakes, alteraciones faciales o manipulaciones de escenas.



Figura 1: De izquierda a derecha: imagen original, deepfake generado y resultado del sistema.

- **Imagen:** detección de artefactos generativos, patrones de compresión anómala y alteraciones locales.
- **Audio:** identificación de patrones asociados a síntesis de voz, manipulación espectral y ataques de repetición, en línea con los enfoques descritos para detección de speech deepfakes [5].
- **Texto:** análisis estilométrico y detección de patrones estadísticos compatibles con generación automática, siguiendo aproximaciones reportadas en la detección de texto generado por modelos neuronales [6].

Los modelos no abordan únicamente la detección como un problema de clasificación binaria, sino que incorporan capacidades de atribución a herramienta o familia generativa y mecanismos de localización de regiones manipuladas orientados a la explicabilidad. Nuestro enfoque combina aprendizaje profundo con algoritmia clásica de análisis forense y procesamiento de señal, integrando patrones de alto nivel aprendidos por redes neuronales con características estadísticas y estructurales más estables. Esta aproximación híbrida incrementa la robustez frente a compresión, postprocesado y posibles estrategias de evasión, considerando principios derivados del estudio de ejemplos adversarios [9].

Además, este enfoque permite una ventaja diferencial del sistema, su capacidad de adaptación a nuevos generadores con un coste reducido en datos y tiempo de ajuste. La arquitectura modular permite incorporar nuevas familias de herramientas generativas sin requerir reentrenamientos completos, facilitando la generalización y reduciendo el tiempo de respuesta ante técnicas emergentes.

El sistema también incluye mecanismos avanzados de explicabilidad, alineados con enfoques generales de interpretabilidad en modelos de aprendizaje automático [10], incluyendo visualización de mapas de atención, como el muestra en la 1 y desgloses por herramienta generativa y presentación estructurada de niveles de confianza (confidence scores). Estos elementos permiten no solo clasificar el contenido, sino también proporcionar información interpretativa útil para entornos forenses y regulatorios.

III-B. Trazabilidad y análisis de origen

La segunda funcionalidad se centra en la trazabilidad del contenido analizado. Mientras que la detección responde a la pregunta de si un contenido presenta indicios de manipulación, la trazabilidad aborda el **análisis de su posible distribución** en canales comunes como aplicaciones de mensajería (Telegram, WhatsApp, ...), redes sociales (Facebook, Instagram, ...) o plataformas de streaming (YouTube, ...).

Esta capacidad incluye:

- Análisis de metadatos asociados a archivos multimedia.
- Identificación de patrones de codificación o procesamiento característicos.

Se combina análisis estructural del archivo con técnicas de correlación de características técnicas. Cuando es posible, los resultados se expresan en forma de indicadores que apoyan la interpretación por parte del usuario final, ya sea en un entorno forense, periodístico o corporativo.

La trazabilidad no siempre permite determinar de forma concluyente la existencia de fraude, pero aporta información contextual valiosa que complementa los resultados de detección.

IV. INTEGRACIÓN, ARQUITECTURA Y DESPLIEGUE

La plataforma VeraQuo ha sido diseñada bajo un enfoque cloud-native y modular, priorizando la integración flexible en entornos heterogéneos y la protección de los componentes con mayor valor estratégico. La arquitectura adopta un modelo basado en microservicios contenedorizados, permitiendo desacoplamiento funcional, escalabilidad horizontal y despliegue portable en distintos entornos.

IV-A. Integración de los diferentes módulos

En el ámbito de la gestión del ciclo de vida del dato, se reforzó el framework interno mediante integración con herramientas de versionado (DVC) y entornos de exploración visual de datasets, facilitando trazabilidad experimental, reproducibilidad y gestión estructurada de anotaciones en escenarios multimodales.

Cada capacidad funcional (detección de imágenes sintéticas y manipuladas, detección de vídeos sintéticos y deepfakes, trazabilidad de imagen, etc.) se implementa como servicios independientes encapsulados en contenedores Docker. Los principales componentes incluyen:

- API REST como punto central de acceso y orquestación.
- Interfaz web para operación interactiva.
- Workers especializados por modalidad (imagen, vídeo, audio, texto).
- Sistema de almacenamiento de objetos compatible con S3.
- Base de datos SQL para metadatos y resultados.
- Sistema de mensajería (RabbitMQ) para gestión asíncrona de tareas.

La comunicación se realiza mediante cola de tareas, desacoplando recepción y procesamiento. Este diseño permite desplegar múltiples instancias de un mismo worker en paralelo sin modificar el código. El modelo de integración incorpora pruebas automatizadas, validaciones de API y ejecución de flujos completos bajo un enfoque S-SDLC.

IV-B. Integración en aplicaciones externas y entornos de videoconferencia

La integración externa se realiza mediante API REST documentada con OpenAPI, facilitando su incorporación en pipelines de identidad digital, sistemas antifraude, gestión documental y análisis multimedia.

En entornos de videoconferencia, el análisis se aplica sobre flujos capturados o grabados, permitiendo evaluar autenticidad en tiempo real o diferido. Para habilitar la captura automatizada en plataformas como Microsoft Teams, Google Meet o Zoom, se ha empleado una API externa de tipo “meeting bot” [12], permitiendo soporte unificado sobre múltiples entornos sin alterar la lógica de las aplicaciones anfitrionas.

IV-C. Protección de la propiedad intelectual y control de uso

Con el objetivo de proteger los activos tecnológicos críticos y garantizar un uso controlado de la plataforma, se han incorporado mecanismos complementarios a distintos niveles.

En primer lugar, las funcionalidades sensibles de detección y carga de modelos se encapsulan en una biblioteca nativa en C++ distribuida en formato binario y expuesta al entorno Python mediante pybind11, lo que dificulta la ingeniería inversa frente a implementaciones puramente interpretadas.

En segundo lugar, los modelos de aprendizaje automático se exportan en formato ONNX cifrado y se desenscriptan exclusivamente en memoria durante la fase de inferencia, evitando su exposición persistente en disco.

Finalmente, la plataforma integra un servidor centralizado de licencias que permite la emisión, revocación y control de uso por cliente, incluyendo limitación temporal y número de ejecuciones. Cada worker valida su licencia en fase de inicialización, bloqueando las funciones críticas en ausencia de autorización válida.

IV-D. Arquitectura y modelos de despliegue

La arquitectura se compone de contenedores Docker independientes para cada componente funcional, lo que permite su orquestación mediante Kubernetes en entornos cloud o mediante Docker Compose en despliegues locales simplificados. Esta aproximación facilita la separación de responsabilidades, el aislamiento de servicios y la adaptación a distintos requisitos operativos.

Actualmente, la plataforma opera en modalidad SaaS sobre un cluster Kubernetes en la nube, donde se han validado mecanismos de escalado automático y monitorización continua. Paralelamente, se dispone de plantillas completas para despliegue on-premises en infraestructuras propias de clientes con requisitos regulatorios o de soberanía del dato.

Este modelo de despliegue garantiza portabilidad sin modificaciones de código, configuración parametrizable mediante variables de entorno, escalabilidad horizontal de workers según carga y tolerancia a fallos mediante reinicio automático y replicación de componentes críticos como base de datos, almacenamiento y sistema de mensajería.

V. IMPACTO Y RESULTADOS

La validación de la plataforma VeraQuo en entorno operacional real ha permitido evaluar no solo el rendimiento técnico de los módulos desarrollados, sino también su grado de integración efectiva en procesos productivos y su capacidad de generar impacto tangible en los sectores objetivo.

V-A. Resultados de la validación operacional

La validación se llevó a cabo con cuatro usuarios finales pertenecientes a sectores diferenciados: verificación de identidad digital, sistemas de voz en contact centers, investigación policial y verificación periodística. En todos los casos, la tecnología fue desplegada sobre infraestructuras reales, integrándose con sistemas hardware y software existentes.

Desde el punto de vista funcional, se verificó que:

- Los módulos de detección eran capaces de procesar contenido multimodal en condiciones reales de variabilidad de formato y calidad.

Tabla I: Rendimiento por módulo (TPR/FPR).

Módulo	Sintético		Manipulado	
	TPR	FPR	TPR	FPR
Imagen (det.)	96/71*	1 %	68 %	1 %
Vídeo (det.)	80 %	1 %	90/80**	1 %
Audio (det.)	94,49 %	1,19 %	76 %	1 %
Texto (det.)	99,55 %	1,37 %	87 %	2,50 %
Imagen (traz.)	98 %	1 %	—	—
Vídeo (traz.)	92 %	1 %	—	—
Audio (traz.)	100 %	0 %	—	—

* Imagen sintética: {lossless, lossy}. ** Deepfake en vídeo: {fondo natural, fondo sintético}.

- Los mecanismos de trazabilidad aportaban información contextual útil para la interpretación de resultados.
- Los sistemas de generación de evidencias producían informes estructurados adecuados para su uso en entornos profesionales.

En términos no funcionales, se evaluaron aspectos críticos para su explotación operativa:

- Estabilidad en operación continuada.
- Compatibilidad con infraestructuras existentes.
- Escalabilidad horizontal mediante despliegue de múltiples instancias.
- Adecuación de tiempos de respuesta a los requisitos de cada caso de uso.
- Correcto funcionamiento de mecanismos de autenticación, control de acceso y licencia.

Adicionalmente, se realizaron pruebas de penetración (pen-testing) sobre la plataforma con el objetivo de identificar vulnerabilidades potenciales y reforzar los mecanismos de seguridad existentes. Estas pruebas incluyeron escenarios de carga concurrente elevada, interrupciones de red y simulaciones de ciberamenazas, permitiendo validar la resiliencia, tolerancia a fallos y robustez del sistema en condiciones adversas. El feedback derivado de estas evaluaciones se incorporó al diseño final, reforzando la integridad de los datos y la resistencia frente a ataques dirigidos.

Para cuantificar el rendimiento de los distintos módulos en condiciones representativas de operación real, se evaluaron métricas de TPR (True Positive Rate) y FPR (False Positive Rate) por modalidad y tipo de manipulación simulando las condiciones de escenarios reales. La Tabla I resume los resultados obtenidos. Los resultados muestran niveles elevados de sensibilidad con tasas de falso positivo contenidas.

VI. TRANSFERENCIA Y MODELO DE EXPLOTACIÓN

El desarrollo de VeraQuo se ha concebido desde sus fases iniciales con un enfoque orientado a la valorización tecnológica y la explotación sostenible de los resultados obtenidos. La estrategia de transferencia combina protección de la propiedad industrial, definición de modelos de negocio y proyección sectorial e internacional.

Desde el punto de vista de la protección tecnológica, se ha adoptado un enfoque híbrido que integra solicitudes de patente para componentes clave del sistema junto con mecanismos complementarios de secreto industrial y control de licencias. Concretamente, en el marco del proyecto se han presentado dos solicitudes de patente con extensión a Europa, EE.UU. y Canadá orientadas a proteger los desarrollos clave asociados.

En cuanto al modelo de explotación, la plataforma se articula en torno a tres modalidades principales: prestación de servicios en modalidad SaaS, despliegue on-premises en infraestructuras de clientes con requisitos regulatorios específicos, e integración mediante API en soluciones de terceros. Esta flexibilidad facilita la adaptación a distintos sectores, incluyendo identidad digital, voz, análisis forense, medios y sector asegurador.

La estrategia contempla además un proceso de verticalización progresiva hacia mercados con alta exposición a amenazas basadas en contenido sintético, así como una expansión internacional alineada con el marco regulatorio europeo, incluyendo el reciente AI Act [11].

VII. CONCLUSIONES

VeraQuo representa un caso consolidado de transferencia tecnológica en el ámbito de la inteligencia artificial aplicada a la ciberseguridad. La validación en entorno operacional real demuestra la madurez técnica y la viabilidad de integración de una plataforma multimodal orientada a la detección y trazabilidad de contenido sintético.

La combinación de arquitectura modular, integración efectiva en procesos productivos y estrategia estructurada de valorización (basada en protección industrial, control de licencias y modelo de explotación flexible) posiciona la solución como un activo transferible con capacidad real de escalado.

Este trabajo refuerza el papel de la investigación aplicada como motor de innovación en la respuesta frente a amenazas derivadas del uso malicioso de IA generativa.

AGRADECIMIENTOS

Este trabajo ha sido financiado por la “Unión Europea NextGeneration-EU, Plan de Recuperación, Transformación y Resiliencia, a través de INCIBE”.

REFERENCIAS

- [1] European Commission, “Technology Readiness Levels (TRL)”, 2014.
- [2] R. Tolosana, R. Vera-Rodriguez, J. Fierrez, A. Morales, and J. Ortega-García, “DeepFakes and Beyond: A Survey of Face Manipulation and Fake Detection,” *IEEE Access*, vol. 8, pp. 90623–90640, 2020.
- [3] L. Verdoliva, “Media Forensics and DeepFakes: An Overview,” *IEEE Journal of Selected Topics in Signal Processing*, vol. 14, no. 5, pp. 910–932, Aug. 2020.
- [4] Y. Mirsky and W. Lee, “The Creation and Detection of Deepfakes: A Survey,” *ACM Computing Surveys*, vol. 54, no. 1, Art. no. 14, pp. 1–41, 2021.
- [5] N. Müller, P. Czempin, F. Dieckmann, A. Froghyar, and K. Böttinger, “Speech Deepfake Detection: A Survey,” *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, vol. 31, pp. 1528–1546, 2023.
- [6] D. Ippolito, D. Duckworth, C. Callison-Burch, and D. Eck, “Automatic Detection of Generated Text is Easiest when Humans are Fooled,” in *Proc. 58th Annual Meeting of the Association for Computational Linguistics (ACL)*, pp. 1808–1822, 2020.
- [7] Europol, “Facing Reality? Law Enforcement and Deepfakes,” Publications Office of the European Union, 2022.
- [8] European Union Agency for Cybersecurity (ENISA), “ENISA Threat Landscape 2023,” 2023.
- [9] I. Goodfellow, J. Shlens, and C. Szegedy, “Explaining and Harnessing Adversarial Examples,” in *Proc. International Conference on Learning Representations (ICLR)*, 2015.
- [10] M. T. Ribeiro, S. Singh, and C. Guestrin, “Why Should I Trust You? Explaining the Predictions of Any Classifier,” in *Proc. 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD)*, pp. 1135–1144, 2016.
- [11] European Parliament and Council of the European Union, “Artificial Intelligence Act,” Regulation (EU) 2024/1689, 2024.
- [12] Recall.ai, “Meeting Bot API,” 2024. [Online]. Available: <https://www.recall.ai/product/meeting-bot-api>

Cyber threat intelligence in the context of information warfare within the EUCINF project

Alejandro David Cayuela Tudela[†], Alejandro Buitrago López[†], Belén Cuesta Bartolomé*, Teresa García de Alcaraz Ruiz[†], Itandehui Gris Sánchez*, Carlos Manchón Vállegas*, Sandra Menasalvas Medina*, Laura Méndez García*, Gregorio Martínez Pérez[†], Frida Muñoz Plaza*, José A. Ruipérez-Valiente[†], José Francisco Suárez Mulero*, Juan Manuel Tejero*, and Javier Pastor-Galindo[†]

[†]Department of Information and Communications Engineering, University of Murcia, 30100 Murcia, Spain
Email: {alejandrodavid.cayuelat, alejandro.buitragol, teresa.garciaa, gregorio, jruiperez, javierpg}@um.es

*Indra Sistemas S.A., Av. de Bruselas, 35, 28108 Alcobendas, Spain
Email: {bcuestab, igris, cmanchon, smmenasalvas, lmendezg, fmplaza, jfsuarez, jmtejero}@indra.es

Abstract—This paper presents a successful model of technology transfer between academia (University of Murcia), industry (Indra) and the defense sector (European Defence) to counter modern information warfare. By adapting mature Cyber Threat Intelligence (CTI) standards, specifically STIX2, to the domain of influence operations, we demonstrate a methodology to transform qualitative disinformation analysis into actionable intelligence within the EUCINF European defence project. This contribution highlights the impact of collaborative R&D in establishing a unified European defense against cognitive threats, emphasizing innovation in automated threat sharing and cross-border cooperation.

Index Terms—Cyber defense, Influence Operations, Information Warfare, Cyber Threat Intelligence

Type of contribution: *Transference*

I. INTRODUCTION

In an increasingly digitalized and globalized world, information has emerged as the second most significant instrument of power, surpassed only by the national economy [1]. Beyond its civilian impact, information plays a crucial role in military strategy, as the rise of influence operations has positioned cyber and information warfare among the most strategic domains of modern conflicts [2], [3]. While deception and influence operations are not new, their scale has been exponentially magnified by modern social networks, where news and opinions can go viral instantly, shaping public opinion and destabilizing institutions [4], [5].

From a cybersecurity perspective, a disinformation campaign can be understood as a set of incidents that deliberately promotes false or misleading information through cyberspace. Much like traditional cyberattacks, these operations erode trust, destabilize markets, and manipulate decision-making processes [6], [7]. Consequently, organizations like the European Union Agency for Cybersecurity (ENISA) now classify disinformation as a major cyber threat [8]. This convergence has given rise to what is termed “cyber-enabled information warfare” (CIW), characterized by the strategic use of digital information to target adversaries’ cognitive processes [9].

To counter these threats, the European Union has recognized the need for structured, interoperable approaches. In the cybersecurity domain, Cyber Threat Intelligence (CTI) has reached high maturity, utilizing standardized languages like STIX2 and protocols like TAXII to share Tactics, Techniques,

and Procedures (TTPs) through platforms such as MISP or OpenCTI [10], [11]. This paper explores the potential of transferring these established CTI methodologies to the domain of information warfare, enabling the programmatic management and exchange of disinformation intelligence [12].

Within this context, the EUCINF project¹ was established to provide a dedicated European framework to tackle the complexities of CIW. Bringing together 22 partners from 12 countries, EUCINF (2023–2026) aims to design and demonstrate advanced CIW capabilities through a toolbox that integrates AI-driven applications, a specialized testbed, and interoperable components. By adopting CTI standards, EUCINF ensures strategic and tactical effectiveness across both civil and military contexts.

II. RELATED INITIATIVES

Detecting and documenting disinformation at scale is essential for understanding the evolving landscape and TTPs used in information manipulation [13]. The current landscape is divided between traditional disinformation repositories and structured CTI platforms and projects.

Several initiatives have emerged to document disinformation campaigns. *EUvsDisinfo* [14] maintains a database of over 20,000 reports. Other specialized efforts include the *Media Manipulation Casebook* and the *Foreign Interference Attribution Tracker (FIAT)* [15].

A group of projects focuses on structured methodologies. The *ADAC.io* project [16] collaborates in the development of the DISARM framework to model the effects of Foreign Information Manipulation and Interference (FIMI). Similarly, the *ATHENA* project [17] uses DISARM to generate knowledge graphs of TTPs, while *SAUFEX* [18] proposes a FIMI dataspace for harmonized exchange. Other projects like *ARM* [19], *DE-CONSPIRATOR* [20], and *RESONANT* [21] focus on identifying authoritarian TTPs and providing policy recommendations. However, these repositories often lack standardized, machine-readable formats, making programmatic consumption difficult, specially for the CTI.

¹<https://www.eucinf.eu>

III. STIX2 CODIFICATION OF DISARM-MODELED DISINFORMATION INCIDENTS

To achieve true CTI compatibility within the EUCINF framework, disinformation incidents modeled via DISARM must be translated into STIX2 objects.

On the one hand, the DISARM framework [22] is selected as the reference model due to its comprehensive integration of Tactics, Techniques, and Procedures (TTPs) tailored for disinformation, mirroring the MITRE ATT&CK structure. Its utility is underscored by its compatibility with STIX2 [23], the provision of an official OpenCTI connector, and endorsements from major international bodies such as ENISA [8], EEAS [24], and the Hybrid CoE [25]. The framework organizes incidents into four sequential phases (PLAN, PREPARE, EXECUTE, and ASSESS) which categorize specific tactics (strategic goals) and fine-grained techniques (actions). For instance, in the “*Ukraine Re-sold French Howitzers*” (URFH) incident [26], Russian actors moved from the PLAN phase (Facilitate State Propaganda) through PREPARE (Create Fake Research) to EXECUTE (Cross-Posting and Use Fake Experts), demonstrating how DISARM effectively decomposes complex influence operations into standardized, actionable intelligence.

On the other hand, STIX2 [10] structures threat intelligence in a standardized, JSON-based format. While traditionally focused on cybersecurity, its architecture (organized into a bundle of interconnected objects representing behaviors, actors, and tools) is sufficiently flexible to accommodate the nuances of influence operations. However, as no formal guidelines yet exist for representing disinformation within STIX2, we have conceptualized a mapping in Table I that abstracts DISARM-based disinformation components into equivalent cybersecurity entities. This approach is particularly powerful for modern conflict scenarios, as it facilitates the simultaneous analysis of cyber and information threats.

A. Disinformation entities in STIX Domain Objects (SDOs)

The first step in this mapping involves identifying the appropriate STIX Domain Objects (SDOs) to represent the core concepts of a disinformation campaign.

- **Incident (IntrusionSet):** This serves as the central anchor of the model. In traditional CTI, an *IntrusionSet* represents a set of adversarial behaviors and resources. In the context of EUCINF, it characterizes the disinformation campaign itself, linking all related actors and techniques. Listing 1 illustrates the URFH case. Note the use of the disinformation label, which facilitates automated filtering in external CTI systems.

```
"id": "intrusion-set--76271730-...",
"type": "intrusion-set",
"spec_version": "2.1",
"name": "Ukraine re-sold French howitzers",
"description": "Claims that Ukraine had sold CAESAR howitzers...",
"labels": [ "incident", "disinformation" ],
"first_seen": "2024-12-25T23:35:11Z"
```

Listing 1: Simplified IntrusionSet SDO

- **Actor (ThreatActor):** Represents the orchestrator of the campaign. Mapping this to *ThreatActor* allows analysts to leverage existing attribution methodologies. As seen in Listing 2, we can categorize the actor (e.g., nation-state) to provide geopolitical context.

```
"id": "threat-actor--7ehead2d-...",
"type": "threat-actor",
"name": "Russia",
"threat_actor_types": [ "nation-state" ]
```

Listing 2: Simplified ThreatActor SDO

- **Technique (AttackPattern):** We utilize the existing work of the DISARM Foundation, which has already mapped its matrix to *AttackPattern* objects. This allows for seamless integration of specific behaviors, such as “*Facilitate State Propaganda*”, into the kill chain phases recognized by platforms like OpenCTI (Listing 3).

```
"id": "attack-pattern--70717452-...",
"type": "attack-pattern",
"name": "Facilitate State Propaganda",
"external_references": {
  "external_id": "T0002",
  "source_name": "DISARM",
  "kill_chain_name": "disarm",
  "phase_name": "plan-objectives"
```

Listing 3: Simplified AttackPattern SDO

- **Country (Location):** To identify the target audience or the region affected by the influence operation, we use the *Location* SDO, as shown in Listing 4.

```
"id": "location--be5032fd-...",
"type": "location",
"name": "France",
"country": "France"
```

Listing 4: Simplified Location SDO

B. Disinformation edges in STIX Relationship Objects (SROs)

The STIX Relationship Objects (SROs) link the SDOs and describe the generated CTI [10]. As shown in Table I, we define three types of standard STIX relationships that relate two pieces of information (SDOs) through their identification:

- **Incident $\xrightarrow{\text{uses}}$ Technique:** Represents the relationship between a *DISARM Technique* and the *Incident* in which it was employed. Typically, an *Incident* involves multiple *Techniques*, resulting in many such relationships. Listing 5 shows the STIX2 representation of the URFH disinformation technique. The *relationship_type* field is set to *uses*, aligning with our definition. The *source_ref* field references the *id* of the *IntrusionSet* representing the URFH *Incident*, while the *target_ref* field points to the *id* of the *AttackPattern* representing the *Facilitate State Propaganda* DISARM *Technique*.

STIX Domain Objects (SDOs) mapping		
Property	STIX2 Object	Rationale
<i>Incident</i>	IntrusionSet	Strategic group of actions with shared objectives.
<i>Actor</i>	ThreatActor	The entity/group responsible for the operation.
<i>Technique</i>	AttackPattern	Specific DISARM tactic or technique employed.
<i>Country</i>	Location	Geographic region or population targeted.
STIX Relationship Objects (SROs) mapping		
Relationship	STIX2 object	Rationale
<i>Incident</i> $\rightarrow$ <i>Technique</i>	uses	A <i>Technique</i> is used in an <i>Incident</i>
<i>Incident</i> $\rightarrow$ <i>Actor</i>	attributed-to	An <i>Incident</i> is attributed to some <i>Actor</i>
<i>Incident</i> $\rightarrow$ <i>Country</i>	targets	An <i>Incident</i> targeting some <i>Country</i>

TABLE I: Mapping between disinformation properties and STIX2 object types.

```
"id": "relationship--1dce08d4-...",
"relationship_type": "uses",
"source_ref": "intrusion-set--76271730-...",
"target_ref": "attack-pattern--70717452-...",
"type": "relationship"
```

Listing 5: Simplified uses SRO

- *Incident* $\xrightarrow{\text{attributed-to}}$ *Actor*: Represents the relationship between an *Actor* and the *Incident* attributed to it. Listing 6 shows the STIX2 representation of the URFH attribution. The `relationship_type` field is set to `attributed-to`. The `source_ref` field references the id of the `IntrusionSet` representing the URFH *Incident*, and the `target_ref` field points to the id of the `ThreatActor` representing the Russia *Actor*.

```
"id": "relationship--dd7da138-...",
"relationship_type": "attributed-to",
"source_ref": "intrusion-set--76271730-...",
"target_ref": "threat-actor--7ebead2d-...",
"type": "relationship"
```

Listing 6: Simplified attributed-to SRO *Incident*

- *Incident* $\xrightarrow{\text{targets}}$ *Country*: Represents the relationship between a *Country* and the *Incident* that targeted it. Listing 7 shows the STIX2 representation of the URFH target. The `relationship_type` field is set to `targets`, indicating the targeting relationship. The `source_ref` field refers to the id of the `IntrusionSet` representing the URFH *Incident*, and the `target_ref` field points to the id of the `Location` object representing the France *Country* targeted in URFH incident.

```
"id": "relationship--c476dlee-...",
"relationship_type": "targets",
"source_ref": "intrusion-set--76271730-...",
"target_ref": "location--be5032fd-...",
"type": "relationship"
```

Listing 7: Simplified targets SRO

To sum up, these STIX2 SDOs and SROs objects constitute

standard representations of DISARM-modeled incidents. In order to be exchanged between CTI peers, they are encapsulated in a STIX2 Bundle, a container used to package and share multiple STIX objects [10].

C. Architectural integration

To operationalize the STIX2 mappings defined in the previous sections, the EUCINF toolbox architecture integrates these objects into a centralized workflow. As illustrated in Figure 1, the Data Lake and indexing component serves as the core repository of EUCINF, including cognitive-based STIX bundles. The architecture facilitates the exchange of these STIX objects across three critical operational layers:

- 1) *Ingestion*: The Data Collection layer feeds the system, initiating the transformation of raw information into the structured STIX format.
- 2) *Enrichment*: The Data Processing and Capitalization and Exploitation components maintain bidirectional communication with the Data Lake. They ingest raw STIX data (such as the `IntrusionSets` and `AttackPatterns` defined in Table I) to perform advanced analytics and return enriched intelligence to the repository.
- 3) *Action*: The Mission Management and Countermeasures component consumes the finalized STIX objects to inform decision-making and deploy response strategies.

This integration ensures that the theoretical CTI models are programmatically accessible to all modules within the EUCINF ecosystem. *No further low-level details can be provided due to limited disclosure policies.*

IV. CONCLUSION

The convergence of traditional cyber threats and strategic influence operations has redefined the modern battlefield, establishing cyber-enabled information warfare (CIW) as a critical domain of national and collective security. This paper has demonstrated that the potential of Cyber Threat Intelligence (CTI) standards, specifically STIX2, provides a robust foundation for treating disinformation not merely as a social phenomenon, but as a programmatic security threat.

By mapping DISARM-modeled incidents to standardized STIX Domain Objects (SDOs) and Relationship Objects (SROs), we enable the automated ingestion, correlation, and sharing of disinformation TTPs within the architecture. This




Fig. 1: Integration of STIX2.1 objects in EUCINF components. *General overview due to limited distribution policies.*

technical interoperability is a cornerstone of the EUCINF project, allowing for a coordinated European response to FIMI.

Future work within the framework will focus on the large-scale validation of these mappings across diverse datasets, ensuring that the European toolbox remains resilient against sophisticated threat actors. Successfully bridging the gap between cybersecurity and information warfare ensures that both civil and military institutions are equipped to defend the integrity of the digital and cognitive commons.

ACKNOWLEDGEMENTS



EUCINF project is co-funded by European Union under grant agreement N°101121418.

REFERENCES

- [1] A. Crowther, "Reorganizing for information competition," in *ICCWS 2018 13th International Conference on Cyber Warfare and Security*. Academic Conferences and publishing limited, 2018, p. 131.
- [2] F. I. Roumpies and A. P. Kakarountas, "Cybersecurity and democracy: A review," in *2023 8th South-East Europe Design Automation, Computer Engineering, Computer Networks and Social Media Conference (SEEDA-CECNSM)*. IEEE, 2023, pp. 1–8.
- [3] J. Pastor-Galindo, P. Nespoli, J. A. Ruipérez-Valiente, and D. Camacho, "Influence operations in social networks," 2025. [Online]. Available: <https://arxiv.org/abs/2502.11827>
- [4] G. Jethava and U. P. Rao, "Exploring security and trust mechanisms in online social networks: An extensive review," *Computers & Security*, vol. 140, 2024.
- [5] S. González-Bailón, D. Lazer, P. Barberá, M. Zhang, H. Allcott, T. Brown, A. Crespo-Tenorio, D. Freelon, M. Gentzkow, A. M. Guess, S. Iyengar, Y. M. Kim, N. Malhotra, D. Moehler, B. Nyhan, J. Pan, C. V. Rivera, J. Settle, E. Thorson, R. Tromble, A. Wilkins, M. Wojcieszak, C. K. de Jonge, A. Franco, W. Mason, N. J. Stroud, and J. A. Tucker, "Asymmetric ideological segregation in exposure to political news on facebook," *Science*, vol. 381, no. 6656, pp. 392–398, 2023.
- [6] K. M. Caramancion, Y. Li, E. Dubois, and E. S. Jung, "The missing case of disinformation from the cybersecurity risk continuum: A comparative assessment of disinformation with other cyber threats," *Data*, vol. 7, 4 2022.
- [7] J. Pastor-Galindo, P. Nespoli, and J. A. Ruipérez-Valiente, "Large-language-model-powered agent-based framework for misinformation and disinformation research: Opportunities and open challenges," *IEEE Security & Privacy*, vol. 22, no. 3, pp. 24–36, 2024.
- [8] European Union Agency for Network and Information Security (ENISA), "Enisa threat landscape 2024," 2024. [Online]. Available: <https://www.enisa.europa.eu/publications/enisa-threat-landscape-2024>
- [9] H. Lin and J. Kerr, "On cyber-enabled information/influence warfare and manipulation," *Center for International Security and Cooperation, Stanford, SAD*, pp. 4–22, 2017.
- [10] R. P. Bret Jordan and T. Darley, "STIX: Version 2.1 — docs.oasis-open.org," <https://docs.oasis-open.org/cti/stix/v2.1/csprd01/stix-v2.1-csprd01.html>, 2019, [Accessed 03-02-2026].
- [11] V. Jesus, B. Bains, and V. Chang, "Sharing is caring: Hurdles and prospects of open, crowd-sourced cyber threat intelligence," *IEEE Transactions on Engineering Management*, vol. 71, pp. 6854–6873, 2024.
- [12] F. S. González, J. Pastor-Galindo, and J. A. Ruipérez-Valiente, "Toward interoperable representation and sharing of disinformation incidents in cyber threat intelligence," 2025. [Online]. Available: <https://arxiv.org/abs/2502.20997>
- [13] E. Kapantai, A. Christopoulou, C. Berberidis, and V. Peristeras, "A systematic literature review on disinformation: Toward a unified taxonomical framework," *New media & society*, vol. 23, no. 5, pp. 1301–1326, 2021.
- [14] "EUvsDisinfo — Detecting, analysing, and raising awareness about disinformation - EUvsDisinfo — euvsdisinfo.eu," <https://euvsdisinfo.eu>, [Accessed 30-01-2025].
- [15] "Interference 2024 — interference2024.org," <https://interference2024.org>, [Accessed 30-01-2025].
- [16] "ADACIO: Attribution, Data Analysis, Countermeasures and Interoperability — adacio.eu," <https://adacio.eu>, [Accessed 03-02-2026].
- [17] "Project Athena — project-athena.eu," <https://project-athena.eu>, [Accessed 03-02-2026].
- [18] "Saufex - Secure Automated Unified Framework for Exchange — saufex.eu," <https://saufex.eu>, [Accessed 03-02-2026].
- [19] "Arm project — www.arm-project.eu," <https://www.arm-project.eu>, [Accessed 03-02-2026].
- [20] "Home - DE-CONSPIRATOR — deconspirator.eu," <https://deconspirator.eu>, [Accessed 03-02-2026].
- [21] "Home - Resonant Project — resonantproject.eu," <https://resonantproject.eu>, [Accessed 03-02-2026].
- [22] S. Terp and P. Breuer, "Disarm: a framework for analysis of disinformation campaigns," in *2022 IEEE Conference on Cognitive and Computational Aspects of Situation Management (CogSIMA)*, 2022, pp. 1–8.
- [23] "GitHub - DISARMFoundation/DISARM-STIX2: A STIX2 generator for the DISARM Framework — github.com," <https://github.com/DISARMFoundation/DISARM-STIX2>, [Accessed 21-02-2025].
- [24] European External Action Service's (EEAS) Stratcom, "1st EEAS report on foreign information manipulation and interference threats," 2 2023. [Online]. Available: https://www.eeas.europa.eu/eeas/1st-eeas-report-foreign-information-manipulation-and-interference-threats_en
- [25] H. Newman, *Foreign information manipulation and interference defence standards: Test for rapid adoption of the common language and framework 'DISARM'*. NATO Strategic Communications Centre of Excellence, 11 2022. [Online]. Available: <https://stratcomcoe.org/publications/foreign-information-manipulation-and-interference-defence-standards-test-for-rap-253>
- [26] R. Osadchuk and Digital Forensic Research Lab, "How russia promoted the claim that ukraine re-sold french howitzers for profit," <https://medium.com/dfirlab/how-russia-promoted-the-claim-that-ukraine-re-sold-french-howitzers-for-profit-1> July 2022, [Accessed 27-01-2026].

ECYSAP EYE: From Cyber Situational Awareness to Mission-Centric Decision Support for Enhanced Cyberspace Operations

Pantaleone Nespoli^{*}, Daniel Díaz-López^{*}, Sergio López Bernal^{*},
Francisco Oliva Bermejo[†], Pedro González Megías[†], Jorge Maestre Vidal[†],
Víctor Sobrino García[‡], Gregorio Martínez Pérez^{*}

^{*}*Departamento de Ingeniería de la Información y las Comunicaciones, Universidad de Murcia, 30100 Murcia, Spain*
{pantaleone.nespoli, danielorlando.diaz, slopez, gregorio}@um.es

[†]*Indra Sistemas S.A., Av. de Bruselas 35, 28108, Madrid, Spain*
{fjolivab, pgmegias, jmaestre}@indra.es

[‡]*Universidad Politécnica de Madrid, Campus de Montegancedo, 28660 Boadilla del Monte, Madrid, Spain*
victor.sobrino@alumnos.upm.es

Resumen—Operational organizations increasingly require Cyber Situational Awareness (CySA) capabilities that go beyond isolated technical alerts, providing mission-relevant artefacts that can be embedded into heterogeneous toolchains and cyber security or cyber defense processes. ECYSAP EYE addresses this need through an adoption-oriented System-of-Systems (SoS) architecture centered on seven groups of mission-focused artefacts: the Recognized Cyberspace Picture (RCyP), Cyber Situational Reports (CySRs), the What-If Analysis Report (WIAR), Option Recommendations (OPRE), an operator Dashboard/HMI (DSH), Action Enforcement (AE), and After-Action Reports (AAR). The ECYSAP EYE architecture structures the transition from perception (full-spectrum RCyP views), to decision-oriented reasoning (WIAR/CySRs/OPRE), and to operational execution and learning (DSH/AE/AAR), with explicit integration surfaces that support incremental deployment and validation. This paper presents this innovative project from a technology transfer perspective, summarizing the updated architecture, the functional role of seven groups of artefacts, and the expected impact of cyber situations on the decision-making process in the context of a mission planning and execution.

Index Terms—Cyber situational awareness, mission engineering, decision support, course of action, system-of-systems

Contribution type: *Transference track*

I. INTRODUCTION

Cyber operations have evolved from isolated technical incidents to sustained and adaptive campaigns capable of degrading critical services while shaping the outcome of military operations in the cyber domain. In the cyber operations environment, cyber effects rarely remain confined to the network perimeter. In fact, disruptions in Communications and Information Services (CIS), compromise of core systems, or manipulation of information flows can propagate to mission assets, degrade combat functions, and ultimately jeopardize mission success. As a result, effective cyber operations require the ability to contextualize cyber actions, anticipate their resulting effects, and support decision-making under time pressure, uncertainty, and operational constraints [1]; which also paves the way for their integration with other domains.

Situational Awareness (SA) is typically described as a three-stage process: (i) *perception* of relevant elements, (ii)

comprehension of their meaning, and (iii) *projection* of their future status to support timely actions in complex environments [2]. In operational cyberspace, the EU and NATO refer to this capability as Cyber Situational Awareness (CYSA), defined as the human ability to gain and maintain current and predictive shared knowledge of cyberspace to support decision-making. Achieving this requires supportive technological solutions capable of producing, maintaining, and disseminating information on friendly and adversarial forces, enabling cyber-focused operational assessment. Beyond data collection (e.g. threat intelligence, anomaly detection, configuration analysis), CySA is supported by tools that integrate heterogeneous signals into a coherent picture, reasoning about mission dependencies, and issuing actionable responses aligned with commander's intent. However, CySA's acquisition remains challenging due to the distributed, incomplete, and dynamic nature of cyber data, the adaptive behavior of adversaries, and the need to balance cyber risks with mission priorities and resource constraints [3].

In light of the above, ECYSAP EYE project aims to advance prior ECYSAP work by strengthening the mission-centric view of cyber risk and by operationalizing decision support through a portfolio of consumable outputs (a Recognized Cyberspace Picture (RCyP), Cyber Situational Reports (CySRs), What-If Analysis Report (WIAR), Option Recommendations (OPRE), Dashboard (DSH), Action Enforcement (AE), and After-Action Reports (AAR)) supported by a modular system-of-systems architecture and an iterative engineering pathway oriented to TRL 6-7 deployment [4].

This paper focuses on ECYSAP EYE project's technology transfer value, i.e., how its concepts and products can be adopted by cyber defence practitioners and integrated into real combat ecosystems. The article provides a concise transfer-oriented overview of ECYSAP EYE, highlighting:

- A high-level SoS architecture of ECYSAP-EYE, focusing on seven operational artefacts that structure the architecture beyond a single shared picture.
- A concise functional description of the core modules/artefacts and how they support end-to-end mission-

centric decision cycles from perception to reasoning and operational action/learning.

- A transfer discussion grounded on modularity, completeness and integration with other defence systems.

II. A EU CYBER SITUATIONAL AWARENESS PLATFORM

European collaboration for military-focused cyber situational awareness initiated with early concepts and specifications sustained by common requirements from multiple Member States (MS), under the coordination of the European Defence Agency (EDA). Among the results that preceded ECYSAP, in 2019 the Cyber Defence Situation Awareness Package Rapid Research Prototype (CySAP-RRP, TRL 4) delivered and proved feasibility in joint CySA related developments, covering dynamic risk assessment and mission impact analysis, considering both mission's attached Communications and Information Services (Technical) and their relevance for the commander's intent (mission) [5].

The project ECYSAP (2020-2024) expanded CySAP-RRP into a broader platform for real-time CySA, adding rapid response functionalities and expanding its decision support functions to satisfy the needs of a wider community of EU MS and their cyber forces. ECYSAP achieved TRL 6-7 and proved cross-national interoperability under NATO's Federated Mission Network (FMN) standards, being able to operate on CLASS/UNCLASS networks. Early results were shown in large military exercises, in support of tactical and operational planning teams, which motivated further transfer and harmonization activities [6].

Building on these foundations, a new development spiral refereed to as ECYSAP EYE (2025-2028) is expanding past capabilities by introducing novel: (i) mission-centric products for decision support, (ii) engineering mechanisms to explore risks/opportunities and adversarial reactions, and (iii) added system integration and deployment readiness aligned with doctrine and training needs.

III. THE ECYSAP EYE'S SOS ARCHITECTURE

A central objective of ECYSAP EYE is to provide mission-centric CySA through a *modular SoS architecture*. This enables: (i) integration of heterogeneous data sources and external services, (ii) deployment across multiple nodes with differentiated responsibilities, and (iii) progressive adoption through incremental capabilities onboarding. Particularly, this architectural approach is relevant for technology transfer, as it reduces integration friction and supports interoperability with existing national/EU/NATO ecosystems.

The operational value is delivered through a set of *artefacts* elaborated by ECYSAP EYE's operators and consumed by mission stakeholders. Figure 1 summarizes the updated high-level architecture as a layered stack that connects (i) operational decision-making, (ii) reasoning and reporting, and (iii) data-driven perception through a full-spectrum RCyP.

At the bottom, the data ingestion component integrates external and contextual sources (e.g. Cyber Threat Intelligence (CTI), Open Source Intelligence (OSINT) and Open Threat Exchange (OTX)) that feed a full-fledged data plane. The latter provides the foundational services required to operationalize ECYSAP EYE, such as normalization, persistence, correlation, and traceability to obtain curated information

products. On top of this base, the **RCyP service** produces a *full-spectrum RCyP* comprising complementary pictures that jointly support mission-centric comprehension. These are tailored for answering each echelon needs for information.

In the middle layer, the **Reasoning layer** transforms full-spectrum RCyP views and **Mission Context** into decision-oriented artefacts. Specifically, **WIAR** supports structured what-if exploration and reasoning under uncertainty. Then, **CySR** provides situation reporting that consolidates evidence into mission-relevant narratives. Last but not least, **OPRE** generates option/recommendation outputs that support response.

Finally, the **Operational layer** exposes these artefacts to mission workflows. **DASH** (dashboard/HMI) acts as primary consumption interface, enabling shared visibility and coordination. Moreover, **AE** captures the execution and enforcement of selected actions, while **AAR** consolidates outcomes for learning and iterative improvement, closing the feedback loop of observation, decision, actuation and evaluation.

In addition to the three-layer stack, Figure 1 highlights two external enablers that support operational deployment and technology transfer across heterogeneous environments. Specifically, Digital Engineering provides integration points with cyber ranges, simulation, and modeling toolchains, enabling controlled experimentation, training, and pre-deployment validation of the artefacts before operational rollout. In parallel, the Interoperability module captures the interfaces required to exchange information products with external military systems, ensuring that RCyP and downstream artefacts can be integrated into joint workflows and multi-stakeholder command structures rather than confined to a standalone platform.

IV. CORE MODULES AND FUNCTIONAL WORKFLOW

To align with operational adoption, ECYSAP EYE is best understood as a pipeline of *core modules* that generate and consume artefacts across the mission decision cycle. Each module is designed to be integrated independently while preserving an end-to-end flow from observations to actuation and learning. While ingestion and data plane provide its technical substrate (collection, normalization, persistence, correlation, and traceability), the operational value and transfer focus lie in the utility of artefacts for mission stakeholders.

First, the RCyP is the artefact that provides a common and authoritative representation of the cyber situation, intended to be shared across echelons and that feeds the Common Operational Picture (COP) from the cyber domain perspective. RCyP is composed of complementary views (cyber technical, CEMA, Cyber Threat, Cognitive, and Mission Tracking), allowing human operators to maintain a consistent baseline that bridges cyber evidence to mission-relevant context. Functionally, RCyP acts as the primary reference for both reasoning outputs and operator-facing interaction.

Then, WIAR operationalizes reasoning through structured exploration of hypotheses and *what-if scenarios*, using RCyP to evaluate plausible evolutions and their consequences, providing the analysis layer that improves adaptive planning and CoA development. WIAR bridges perception with decision-ready understanding and projection under operational friction.

In addition, CySR consolidates relevant RCyP and reasoning outcomes into situation reporting suitable for operational




Figure 1. High-level System-of-Systems (SoS) architecture vision for ECYSAP EYE

briefings and coordination. This reduces the need for human intervention when writing.

Also, OPRE produces option/recommendation outputs by linking assessed potential risks and opportunities to feasible operational responses derived from RCyP and WIAR outcomes. That is, this component supports prioritization and trade-offs (e.g. mission impact versus mitigation cost or constraints) and provides structured inputs for high-level decisions.

At a higher level, DSH can be described as the primary human operator-facing interface for consuming and coordinating the ECYSAP EYE's artefacts. Concretely, it supports shared visibility, role-based interaction, and integration into existing command chain workflows, acting as the practical "entry point" and awareness-ready module for operational use.

Moreover, AE captures the operationalization of selected decisions by supporting and tracking the enforcement of actions. Specifically, AE closes the gap between recommendations and real operational actions, providing status and traceability so that outcomes can be related back to the decisions and the underlying evidence and services.

Finally, AAR closes the loop by consolidating outcomes, and fostering the lessons identified and learned process while enabling operational assessment. AAR links observed effects (leveraging AE and the constantly evolving RCyP) to the decision process (i.e. WIAR and OPRE), supporting accountability, training, and iterative improvement of both procedures and configurations. This assessment artefact is particularly relevant for technology transfer, where trust-building and institutionalization typically require documented validation cycles to support potentially disruptive decisions.

sectionTechnology Transfer Value and Expected Impact

A key objective of ECYSAP EYE is to maximize operational adoption by reducing integration friction and enabling progressive onboarding of capabilities. From a transfer perspective, the relevant question is not only *what* the system provides, but *how* its seven groups of artefacts can be embedded into real ecosystems where tooling, data availability, military doctrine, and operational responsibilities differ across organizations (and potentially across nations). In addition to adopting interoperability standards like FMN, the SoS design

in Figure 1 supports this ambitious goal by structuring a clear transition from perception to reasoning to operational execution, with explicit integration surfaces that enable incremental deployment and validation across heterogeneous environments

IV-A. Transfer-Oriented Adoption: Integration Readiness

The proposed architecture enables stakeholders to adopt the artefact stack progressively. At the perception level, the RCyP provides a shared, full-spectrum baseline representation of the operational cyber landscape that can be exposed to both operators and external systems. On top of this baseline, reasoning artefacts (i.e., CySRs, WIAR, OPRE) can be introduced incrementally to support structured planning based on the information provided by mechanisms as what-if exploration, situation reporting, and options/recommendations, respectively. From an operational perspective, WIAR enables the preparation of alternative ways of action for contingency plans before missions. The RCyP provides the landscape status and configuration to the user. Once an event occurs, the OPRE will compute and provide response options in the cyber domain to officers for their approval, while the AE/AAR will monitor the event and the decision-making process to provide effect assessment and analysis to improve the effectiveness of subsequent recommendations and actions.

On the consumption side, DSH offers a stable integration point for command workflows by providing role-oriented access to the artefacts, while interoperability interfaces facilitate coupling with external EU/NATO/national systems where required. In addition, digital-engineering connectors (cyber ranges, simulation, models) support controlled testing and training, which are often prerequisites for operational rollout and institutionalization.

The proposed architecture ensures cyber and operational domains are recognizable at both tactical and operational levels of war by first integrating information into mission and operational pictures, while providing commanders with the necessary tools that support their cyber operations by facilitating common understanding of the situation, and contributing to a more effective employment of their cyber forces.

Tabla I
MAIN ECYSAP-EYE'S ARTEFACTS AND TRANSFER VALUE (SUMMARY).

Artifact/Service	Primary user	What it provides	Transfer value
Recognized Cyberspace Picture (RCyP)	Joint Operation Center (JOC)/external systems	Full-spectrum cyber picture (Cyber Technical, CEMA, Cyber Threat, Cognitive, Mission Tracking views)	Shared landscape across systems and domains; improves coordination and interoperability-ready consumption
Cyber Situational Reports (CySRs)	Command staff/operators	Reporting artifact consolidating evidence into mission-relevant narratives	Standardizes communication; improves comprehensive and coordinated conduct of operation
What-If Analysis Report (WIAR)	Analysts/staff	Structured what-if exploration (assumptions, hypotheses, projections, consequences)	Supports explainable reasoning; facilitates scenario-based validation and trust building; supports planning
Option Recommendations (OPRE)	Commander/planners	Options and recommendations linked to assessed risks/opportunities	Enables prioritization and traceable decision justification; supports repeatable procedures; enables alternate CoA development
Dashboard (DSH)	Operators/Commander	Operator-facing interface to consume RCyP, CySRs, WIAR, OPRE	Embeds artefacts into real workflows; lowers adoption barriers via usable operational interface
Action Enforcement (AE)	Response teams/operators	Enforcement tracking of selected actions and status/outcomes	Bridges decisions to operational effects; enables traceability and integration with toolchains; provides cost-effectiveness analysis
After-Action Reports (AAR)	Commander/Auditors/QA	Post-operation assessment: outcomes, lessons learned, feedback	Closes the learning loop; supports institutionalization, training, and continuous improvement

IV-B. Operator-Facing Outputs

Table I summarizes the seven artefacts and their primary transfer value. The emphasis is on delivering operator-ready artefacts that support mission-centric decision cycles, that is, a shared baseline picture (RCyP), decision-oriented reasoning products (CySRs, WIAR, OPRE), and operational loop closure (DSH, AE, AAR).

In particular, RCyP operationalizes shared situational awareness by providing synchronized and traceable views (Cyber Technical, CEMA, Cyber Threat, Cognitive, and Mission Tracking pictures) that can be consumed consistently across teams and, when needed, external systems. In this way, RCyP is able to reduce ambiguities in joint decision-making and supports coordination under time pressure, fostering a unique and easily interpretable common operational picture that successfully integrates the cyber and cognitive domains.

Similarly, the reasoning artefacts are intended to produce interpretable outputs. Particularly, i) WIA captures structured what-if exploration grounded in mission context, enabling pre-planned response options, ii) CySRs consolidate evidence into mission-relevant narratives suitable for briefings and coordination, and iii) OPRE links assessed risks/opportunities to feasible response options and recommendations, expediting the development of CoAs and linking WIA planning with OPRE conduction. These artefacts are consumed through DSH, which acts as the primary operator interface and supports the transition from perception (RCyP) to comprehension and projection (WIAR/CySRs/OPRE), enabling timely decision-making during mission planning and execution.

Finally, operationalization requires traceability from decisions to effects and back to improvement. AE incorporates effect-based analysis of operations based on the recorded status and outcomes of the entire process, while AAR consolidates evaluation, operational assessment, and lessons learning. This explicit closure is particularly relevant for technology transfer, as operator trust and procedural alignment are typically established through iterative validation cycles rather than one-off integration efforts.

IV-C. Expected Impact

By aligning cyber evidence with mission context and delivering a TRL 6-7 with an SoS architecture centered on operational artefacts, ECYSAP EYE is positioned to strengthen decision-making and coordination across mission planning and execution. The explicit inclusion of interoperability and digital-engineering integration supports transfer into operational environments, where evaluation, training, and interconnec-

tion with existing systems are prerequisites for adoption. In particular, combining a shared RCyP baseline with structured reasoning and action/learning artefacts (WIAR/CySRs/OPRE, AE/AAR) can reduce the gap between technical cyber assessments and mission-level decisions, enabling faster coordination among stakeholders and more consistent justification of response options.

V. CONCLUSION

This paper presented ECYSAP EYE from a technology-transfer perspective, emphasizing the project's artifact-centric approach and its layered SoS architecture that connects perception (RCyP), decision-oriented reasoning (WIAR, CySRs, OPRE), and operational execution (DSH, AE, AAR). The resulting decomposition provides a practical path from cyber evidence and mission context to mission-centric decision support while preserving deployment flexibility and integration readiness. It is important to remark that the project remains under development in close connection with the Ministries of Defense (MoDs) involved, with ongoing integration and validation activities aimed at operational adoption.

ACKNOWLEDGMENT

^{EU} This work has been co-funded by the European Union (EDF program; project ECYSAP EYE). Views and opinions expressed are however those of the author(s) only and do not necessarily reflect those of the European Union or the European Defence Fund. Neither the European Union nor the granting authority can be held responsible for them.

REFERENCIAS

- [1] A. Kott, J. Ludwig, and M. Lange, "Assessing mission impact of cyberattacks: Toward a model-driven paradigm," *IEEE Security & Privacy*, vol. 15, no. 5, pp. 65–74, 2017.
- [2] M. R. Endsley, "Final reflections: Situation awareness models and measures," *Journal of Cognitive Engineering and Decision Making*, vol. 9, no. 1, pp. 101–111, 2015.
- [3] L. Jiang, A. Jayatilaka, M. Nasim, M. Grobler, M. Zahedi, and M. A. Babar, "Systematic literature review on cyber situational awareness visualizations," *IEEE Access*, vol. 10, pp. 57 525–57 554, 2022.
- [4] J. A. Montero, "La transformación de la inteligencia a través de la innovación," *Cuaderno de Inteligencia 3. La innovación tecnológica en el área de la inteligencia de ciberramenazas y por extensión de la ciberdefensa*, vol. 1, no. 1, pp. 149–188, 2025.
- [5] European Defence Agency (EDA), "CySAP-RRP: Cyber Defence Situation Awareness Package – Rapid Research Prototype," <https://www.eda.europa.eu>, 2020, accessed: 2026-02-23.
- [6] European Commission, "EDIDP – ECYSAP: European Cyber Situational Awareness Platform," <https://ec.europa.eu/commission/presscorner/api/files/attachment/865731/EDIDP%20-%20ECYSAP.pdf.pdf>, 2019, european Defence Industrial Development Programme (EDIDP) factsheet. Accessed: 2026-02-23.

Sesión de pósters 1

NoRDEx: Un protocolo descentralizado optimista de no repudio para intercambios de datos

Fernando Román-García, Antonio Alarcón, Juan Hernández Serrano, Oscar Esparza, Jorge Mata

Universitat Politècnica de Catalunya (UPC)

fernando.roman@upc.edu, antonio.alarcon@upc.edu, j.hernandez@upc.edu, oscar.esparza@upc.edu, jorge.mata@upc.edu

Resumen—El artículo presenta el protocolo NoRDEx, diseñado para garantizar el no repudio en intercambios de datos. NoRDEx puede considerarse descentralizado, ya que elimina la necesidad de una TTP centralizada mediante el uso de un DLT para almacenar pruebas criptográficas sin revelar el mensaje intercambiado. NoRDEx es un protocolo de no repudio optimista, ya que solo utiliza la DLT en caso de disputa. El protocolo ha sido implementado y probado en entornos del mundo real, con evaluaciones de rendimiento que cubren costos, sobrecarga y tiempo de ejecución. Un análisis formal de seguridad utilizando el modelo lógico SVO demuestra la capacidad de NoRDEx para resolver disputas de manera segura.

Index Terms—No repudio, Intercambio Justo, Distributed Ledger, Blockchain

Tipo de contribución: Investigación ya publicada

I. INTRODUCCIÓN

Los mercados de datos requieren soluciones al problema del intercambio justo [1]: evitar que una parte incumpla tras la acción de la otra. Aunque los protocolos de no repudio (NRO/NRR) [2], [3] mitigan esto, tradicionalmente dependen de una TTP centralizada [4]. El uso de DLTs permite descentralizar esta figura, pero las propuestas actuales suelen presentar altos costes [5] o acoplan rígidamente el pago al intercambio de datos, limitando su uso en dominios con canales de pago tradicionales.

Este trabajo presenta NoRDEx, un protocolo de no repudio descentralizado y optimista desarrollado en el marco de i3-MARKET [6]. NoRDEx destaca por cinco requisitos clave: 1) **pago desacoplado**, permitiendo cualquier método; 2) **resolución de disputas** mediante evidencias auditables; 3) **descentralización** eliminando TTPs únicas; 4) **ejecución optimista**, interactuando con la DLT solo en caso de conflicto; y 5) **privacidad** de los intervinientes y datos. El protocolo incluye un análisis formal bajo el modelo lógico SVO y su implementación es de código abierto [7], [8]. El artículo original [9] detalla todos los aspectos del protocolo y su evaluación de rendimiento.

II. ESTADO DEL ARTE

Las primeras soluciones de no repudio dependían de TTPs centralizadas para notarizar la entrega [10] o implementaban protocolos optimistas para reducir la latencia [11]. Otros enfoques buscaron eliminar las TTPs mediante soluciones probabilísticas basadas en fragmentación de mensajes [12] o cifrado retardado [13], aunque sin garantizar certeza absoluta en el intercambio.

Con la aparición de las DLTs, han surgido protocolos que integran el no repudio en el consenso [14] o facilitan el intercambio justo mediante contratos inteligentes y árboles de

Merkle [15]. Investigaciones recientes se centran en optimizar la eficiencia para casos de uso específicos como escenarios IoT [16]. Sin embargo, a diferencia de NoRDEx, estas propuestas no logran un intercambio eficiente que desacople totalmente el sistema de pago manteniendo una arquitectura descentralizada y optimista.

III. RESUMIENDO NORDEX

Como se ha mencionado en la Sección I, NoRDEx es un protocolo optimista de no repudio que proporciona un mecanismo para contabilizar de manera fiable un intercambio de datos, permitiendo que el proveedor y el consumidor verifiquen cuándo tuvo lugar el intercambio, la integridad de los datos recibidos y su recepción dentro del plazo acordado.

III-A. Premisas

En esta sección se introducen tres conceptos fundamentales para comprender el protocolo: el acuerdo, el intercambio de datos y las pruebas. Es importante definirlos explícitamente, ya que pequeñas variaciones pueden afectar tanto la seguridad como la claridad del protocolo. En esta sección se usa una terminología específica, en la que Pedro representa al proveedor y Carla al consumidor.

III-A1. Acuerdo:

Para ejecutar el protocolo NoRDEx, es necesario que tanto Pedro como Carla hayan establecido previamente un acuerdo que regule el intercambio de datos. Este acuerdo define las identidades digitales de ambas partes, las condiciones básicas del servicio, la interacción con la DLT, los algoritmos criptográficos que se utilizarán y otros parámetros opcionales.

III-A2. Intercambio de datos:

Una vez que Carla y Pedro tienen un acuerdo, el contrato inteligente de NoRDEx puede asegurar el intercambio de uno o varios mensajes bajo las condiciones especificadas en dicho acuerdo. Para identificar de forma única e inequívoca cada intercambio de mensajes, se define el identificador único de intercambio *eid*, calculado como el hash de la concatenación del acuerdo asociado, el hash del texto cifrado $hash(c)$ y el hash de la clave de descifrado $hash(k)$.

Esta estructura es crucial para verificar que tanto el mensaje cifrado como la clave corresponden al intercambio. Los únicos parámetros que serán públicos en la DLT son el identificador del proveedor, el *eid* y la clave *k*. El resto se mantiene privado o se intercambia solo entre consumidor y proveedor a través de un canal seguro.

III-A3. Pruebas:

La ejecución del protocolo requiere que tanto Carla como Pedro generen y verifiquen pruebas criptográficas, o simplemente *pruebas*.

NoRDEx tiene tres tipos de pruebas, cada una con un propósito específico en el protocolo:

- Prueba de Origen (π_{PoO}): generada por Pedro y retenida por Carla. Evita que Pedro niegue haber enviado m . Las afirmaciones en π_{PoO} son la tupla $\phi_{PoO} := (type, iss, iat, e)$.
- Prueba de Interés (π_{PoI}): generada por Carla y retenida por Pedro. Confirma el interés de Carla en adquirir m , y evita que niegue haberlo recibido.
- Prueba de Clave (π_{PoK}): generada por Pedro y retenida por Carla. Evita que Pedro niegue haber enviado una clave concreta.

III-B. Intercambio de datos simplificado de NoRDEx




Figura 1. Simplified outline of the NoRDEx operation

La Figura 1 muestra una representación simplificada del protocolo NoRDEx. Aunque esta vista es una simplificación, resulta útil para entender su estructura básica.

IV. CONCLUSIONES

A lo largo de este resumen hemos presentado NoRDEx, un protocolo que genera evidencias para garantizar el no repudio en los intercambios de datos, protegiendo tanto al proveedor —que puede demostrar que el consumidor recibió los datos— como al consumidor —que puede probar que datos recibió y en qué momento—. Estas evidencias permiten una contabilidad y facturación justas, y pueden emplearse como soporte en la resolución de posibles disputas.

NoRDEx ha sido diseñado para proporcionar no repudio sin necesidad de una TTP. De hecho, un contrato inteligente ejecutado sobre una DLT, intrínsecamente distribuida y fiable, asume el papel de la TTP. Dado que la conexión con la infraestructura externa puede ser una fuente potencial de latencia, nuestro protocolo utiliza la DLT únicamente de forma optimista.

Consideramos que NoRDEx ofrece una solución flexible, segura y eficiente que puede impulsar el intercambio de datos en los mercados y otros entornos digitales.

AGRADECIMIENTOS

Esta iniciativa se realiza en el marco de los fondos del Plan de Recuperación, Transformación y Resiliencia, financiadas por la Unión Europea (Next Generation), dentro de la cátedra INCIBE CARISMATICA (C066.23_UPC), bajo el Proyecto PID2024-159480OB-I00 financiado por MICIU/AEI/10.13039/501100011033, por “FEDER/UE”, por la Generalitat de Catalunya bajo el proyecto 2021-SGR-00594 y con el apoyo del programa de ayudas predoctorales FI STEP del Departament de Recerca i Universitats de la Generalitat de Catalunya y el cofinanciamiento por el Fondo Social Europeo Plus (FI STEP 00508).

REFERENCIAS

- [1] M. Arenas, P. Barceló, L. Libkin, and F. Murlak, *Foundations of Data Exchange*. Cambridge University Press, 2014.
- [2] J. Zhou and D. Gollmann, “Evidence and non-repudiation,” *Journal of Network and Computer Applications*, vol. 20, no. 3, pp. 267–281, 1997. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1084804597900564>
- [3] B. Schneier, *Foundations*. John Wiley & Sons, Ltd, 2015, ch. 1, pp. 1–18.
- [4] H. Pagnia, F. C. Gärtner *et al.*, “On the impossibility of fair exchange without a trusted third party,” Citeseer, Tech. Rep., 1999.
- [5] V. Buterin and M. Swende, “EIP-2929: Gas cost increases for state access opcodes,” 2020, accessed: 2023-09-05. [Online]. Available: <https://eips.ethereum.org/EIPS/eip-2929>
- [6] European Union, “Intelligent, Interoperable, Integrative and deployable open source MARKETplace with trusted and secure software tools for incentivising the industry data economy - i3-MARKET. H2020-ICT-2019-2 871754,” 2023. [Online]. Available: <https://www.i3-market.eu/>
- [7] i3 MARKET, “NoRDEx git repository,” 2024. [Online]. Available: <https://github.com/i3-Market-V3-Public-Repository/SP3-SCGBSSW-CR-NonRepudiationLibrary>
- [8] —, “NRP contract git repository,” 2024. [Online]. Available: <https://github.com/i3-Market-V3-Public-Repository/SP3-SCGBSSW-CR-NonRepudiationProtocolSmartContract>
- [9] F. Román-García, J. Hernández-Serrano, and O. Esparza, “Nordex: A decentralized optimistic non-repudiation protocol for data exchanges,” *Journal of Network and Computer Applications*, vol. 243, p. 104291, 2025. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1084804525001882>
- [10] M. Blaze, G. Bleumer, and M. Strauss, “Divertible protocols and atomic proxy cryptography,” in *Advances in Cryptology — EUROCRYPT’98*, K. Nyberg, Ed. Berlin, Heidelberg: Springer Berlin Heidelberg, 1998, pp. 127–144.
- [11] J. A. Onieva, J. Zhou, and J. Lopez, “Non-repudiation protocols for multiple entities,” *Computer Communications*, vol. 27, no. 16, pp. 1608–1616, 2004. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0140366404002269>
- [12] O. Markowitch and Y. Roggeman, “Probabilistic non-repudiation without trusted third party,” in *Second Conference on Security in Communication Networks*, vol. 99, 1999, pp. 25–36.
- [13] I. Maffei and A. W. Roscoe, “Optimally-fair exchange of secrets via delay encryption and commutative blinding,” in *International Conference on Financial Cryptography and Data Security*. Springer, 2023, pp. 94–111.
- [14] L. Wang, J. Liu, and W. Liu, “Staged data delivery protocol: A blockchain-based two-stage protocol for non-repudiation data delivery,” *Concurrency and Computation: Practice and Experience*, vol. 33, 03 2021.
- [15] S. Delgado-Segura, C. Pérez-Solà, G. Navarro-Arribas, and J. Herrera-Joancomartí, “A fair protocol for data trading based on bitcoin transactions,” *Future Generation Computer Systems*, vol. 107, pp. 832–840, 2020. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0167739X17318344>
- [16] J. Sengupta, S. Ruj, and S. Das Bit, “Fairshare: Blockchain enabled fair, accountable and secure data sharing for industrial iot,” *IEEE Transactions on Network and Service Management*, vol. 20, no. 3, pp. 2929–2941, 2023.

Automated Hyperledger Fabric Deployment for Continuous Cybersecurity Certification

Álvaro Navarro Martínez, Sara Nieves Matheu García, Antonio Fernando Skarmeta Gómez

Facultad de Informática, Universidad de Murcia, Murcia, España
{a.navarro, saranieves.matheu, skarmeta}@um.es

Abstract—Traditional cybersecurity certification relies on periodic assessments that quickly become outdated in dynamic ICT environments. Emerging regulations instead require continuous assurance supported by up-to-date evidence collected throughout the product lifecycle. However, certification involves multiple independent stakeholders who must exchange and verify evidence without relying on a centralized trusted intermediary, making integrity and accountability across organizational boundaries a challenge. This paper presents the design and implementation of a distributed trust infrastructure for continuous certification within the COBALT framework using Hyperledger Fabric. Certification evidence managed off-chain by each stakeholder is anchored on the ledger through cryptographic proofs that ensure integrity, verifiable provenance, and auditability while preserving confidentiality. To enable practical adoption, we introduce an automated deployment framework that provisions permissioned ledger networks from declarative specifications, enabling reproducible deployment and seamless integration into certification workflows. The resulting system demonstrates how automated provisioning of distributed ledgers can support continuous cybersecurity certification in multi-stakeholder environments.

Index Terms—Hyperledger Fabric, Automated Deployment, Continuous Certification, Multi-Stakeholder Networks, Distributed Ledger

I. INTRODUCTION

The rapid digitalization of critical infrastructures has exposed a gap between the operational reality of ICT systems and their certification status. Traditional schemes rely on static evaluations that remain valid for years, yet systems certified today may become vulnerable tomorrow. To address this, the EU Cybersecurity Act (CSA) [2] introduced a harmonized certification framework, while the Cyber Resilience Act (CRA) [1] mandates security across the entire product lifecycle. However, implementing continuous assurance through manual audit procedures remains administratively unfeasible.

This certification model involves multiple independent stakeholders (manufacturers, certification authorities, and operators) who must exchange and validate security evidence without relying on a centralized intermediary. The COBALT framework addresses this by proposing a decentralized platform that automates continuous certification, integrating monitoring, assessment, and decision-making components with a Distributed Ledger Technology (DLT) infrastructure based on Hyperledger Fabric.

This paper presents the design and implementation of the distributed trust layer within COBALT, with three main contributions:

- 1) An automated infrastructure-as-code system that transforms declarative JSON specifications into fully operational Hyperledger Fabric networks.
- 2) A privacy-preserving multi-channel architecture that enforces data sovereignty among certification stakeholders.
- 3) An integration layer bridging the COBALT ecosystem with the permissioned ledger through federated identity mapping and a REST API gateway.

II. RELATED WORK

Blockchain technology has been recognized as a key enabler of distributed trust in multi-stakeholder certification ecosystems. Neisse *et al.* [4] introduced an interledger-based cybersecurity certification framework for the EU Cybersecurity Act, demonstrating how permissioned ledgers can support cross-border security assurance. However, such works focus on what a trust platform should achieve rather than on the DevOps challenges of deploying it across organizations.

Deploying Hyperledger Fabric is widely regarded as error-prone and time-intensive, requiring careful PKI configuration, MSP management, and multi-component orchestration [5]. Tools such as Minifabric [8] and Fabio [9] partially automate basic deployments, and platforms like HFabD+M [6] offer web-based provisioning. Nevertheless, existing solutions do not support *declarative, trust-centric* network definitions where operators specify governance and trust requirements at a high level. Our work bridges this gap by enabling developers to define consortium networks declaratively, which the system deploys automatically.

III. THE COBALT FRAMEWORK

COBALT is a Horizon Europe project that proposes a decentralized platform for automated continuous certification of ICT products, aligned with the CSA, CRA, and NIS2 regulatory frameworks [1]–[3]. Its architecture (Fig. 1) comprises four layers: the *Operations Layer* abstracts the Target of Evaluation through a Security Digital Twin; the *Assessment Layer* transforms telemetry into risk insights using a Common Certification Model (CCM); the *Management Layer* coordinates workflow orchestration and autonomous decision-making; and the *Distributed Trust Layer*, built on Hyperledger Fabric, provides tamper-proof evidence anchoring across organizational boundaries.




Fig. 1. COBALT layered architecture.

The certification process involves three independent stakeholders (Manufacturers, Conformity Assessment Bodies (CABs), and Operators) who must exchange and verify certification artifacts without relying on a centralized authority. Fabric's permissioned nature ensures cryptographic accountability, while its channel capability enables logical data segregation. The ledger acts as a cryptographic anchoring layer: only hashes are committed on-chain, preserving data sovereignty while providing audit trails. Evidence is structured using the OSCAL metamodel [10] for interoperability across the certification ecosystem.

IV. SYSTEM DESIGN AND IMPLEMENTATION

A. Declarative Deployment Model

To mitigate the well-documented complexity of Hyperledger Fabric deployments [7], our system derives the entire network topology from a single declarative JSON configuration file that specifies three logical sections: *organizations* (participating domains and roles), *channels* (channel-to-member mappings encoding trust boundaries), and *chaincodes* (smart contract sources, versions, and target channels). This separates *intent* from *mechanics*, allowing the automation engine to handle all low-level configuration.

The orchestration script programmatically provisions the infrastructure in a strict sequence: (1) PKI generation via dedicated Fabric CA servers for each organization, producing the full certificate hierarchy and MSP directory structure; (2) configuration artifact synthesis (`configtx.yaml`, genesis block, channel transactions, anchor peer updates); and (3) container orchestration through generated Docker Compose files connecting peers, orderers, and CouchDB instances. The system further automates the Fabric 2.x chaincode lifecycle, handling compilation, installation, organizational approval, and commitment without manual intervention. The implementation was validated on a virtual machine running Ubuntu 22.04 LTS (4 vCPU, 16 GB RAM) using Fabric v2.5 with Raft-based ordering.

B. Network Topology

Based on the COBALT stakeholder model, the Fabric network comprises three organizations (Manufacturer, Domain Operator, and Certification Authority) interconnected through three segregated channels (Fig. 2):




Fig. 2. Hyperledger Fabric architecture for COBALT.

- **Artifact Channel** (Manufacturer ↔ Operator): secure distribution of product information (SBOMs, HBOMs).
- **Certification Channel** (CAB ↔ Manufacturer): certificate issuance and compliance verification.
- **Vulnerability Channel** (Operator ↔ CAB): runtime incident reporting for certification revocation decisions.

Access control is enforced via chaincode logic that validates the invoker's MSP ID, restricting write operations to authorized organizations per channel.

C. Smart Contract and Integration

The business logic implements a hash-on-chain anchoring pattern: the smart contract computes a SHA-256 hash of the submitted evidence within the chaincode execution context, ensuring deterministic consensus across endorsing peers. Only the hash and metadata (submitter MSP ID, timestamp) are stored on-chain, while raw evidence remains off-chain under each stakeholder's control. This design enforces idempotency (duplicate submissions are rejected) and provides verifiable provenance for all certification artifacts.

Integration with the COBALT ecosystem is achieved through a Node.js REST API Gateway that implements a federated identity mapping pattern. When a request arrives

with a valid OIDC token from the COBALT Identity Manager, the gateway maps the authenticated user to the corresponding Fabric MSP identity for transaction signing. The API uses the fabric-network SDK's `submitTransaction` method to block until commitment, ensuring that a successful HTTP response guarantees ledger immutability. RESTful endpoints (e.g., `POST /v1/evidence`) are documented via OpenAPI, allowing heterogeneous COBALT components to interact with the blockchain transparently.

V. VALIDATION

The system was validated within the COBALT testbed, hosted on a Proxmox VE virtual machine running Ubuntu 22.04 LTS (4 vCPU, 16 GB RAM) with Fabric v2.5.14, Raft ordering, CouchDB 3.5 state database, and Docker 28.1. Functional validation confirmed the complete evidence anchoring workflow: a Manufacturer submits an SBOM via the REST API, the gateway maps the request to the `Org1MSP` identity, the smart contract computes and anchors the SHA-256 hash on the `artifact` channel, and a third party verifies the evidence by querying the ledger. The average end-to-end latency from HTTP request to block commitment was 2.1 s.

A. Deployment Efficiency

Table I compares the automated approach against manual deployment for the COBALT topology (3 organizations, 3 channels, 3 chaincodes). Five independent full-lifecycle runs from a clean state yielded a mean total provisioning time of 123.89 ± 2.73 s, broken down as: PKI bootstrapping via Fabric CA (25.60 ± 2.73 s), channel configuration artifact generation (0.87 s), container orchestration file synthesis (0.15 s), network launch with channel joins (30.44 ± 2.55 s), and chaincode compilation plus Fabric 2.x lifecycle management (66.83 ± 1.68 s). In our setup, the chaincode phase was the largest contributor, likely due to Gradle compilation and the multi-step approve-commit protocol.

TABLE I
DEPLOYMENT COMPARISON: MANUAL VS. AUTOMATED

Metric	Manual Setup	Automated (Ours)
Config Files Edited	~12 (YAMLs)	1 (JSON)
Crypto-Material Gen.	Manual Steps	Auto-Generated
Deployment Time	~4-6 Hours	123.89 ± 2.73 s
Human Error Risk	High	Minimal

B. Ledger Performance

To evaluate transaction processing capacity, we conducted controlled micro-benchmarks using Hyperledger Caliper [11], the standard performance evaluation framework for Hyperledger blockchains. Two Caliper workers submitted 300 transactions at a fixed rate of 30 TPS across three workload types: pure writes (`putValue`), pure reads (`getValue`), and mixed operations (50% write, 50% read).

TABLE II
LEDGER PERFORMANCE UNDER SUSTAINED LOAD (30 TPS)

Workload	Succ	Fail	Avg Lat. (s)	Thr. (TPS)
write	300	0	0.28	30.0
read	300	0	0.01	30.2
mixed	290	10	0.30	29.9

As shown in Table II, the network sustained the target write throughput with sub-second latency (0.28 s average), confirming that the Raft ordering service and endorsement policies process blocks efficiently under this load. Read latency was an order of magnitude lower (0.01 s), consistent with Fabric's read path (`evaluateTransaction`) querying the peer's local CouchDB directly without ordering or commitment. The comparison of the 0.28 s ledger write latency with the 2.1 s full API workflow suggests that application-layer processing (including OIDC token verification, federated identity mapping, and SDK initialization) contributes substantially to end-to-end latency beyond ledger commit. Under mixed concurrency, 10 transactions (3.3%) were invalidated with status consistent with `MVCC_READ_CONFLICT`, an expected behavior in Fabric's optimistic Execute-Order-Validate model when concurrent transactions access overlapping state versions within the same block window.

The evaluation has several limitations. First, the testbed uses a single Raft orderer on a single host; production deployments require a cluster of at least three orderers for crash fault tolerance. Second, the 3.3% conflict rate under concurrent mixed workloads is inherent to Fabric's optimistic concurrency and is mitigated in practice through application-layer retry logic. Third, while the declarative framework supports arbitrary N -organization, M -channel topologies, the evaluation was conducted with the three-organization COBALT reference configuration; scalability to larger consortia and WAN deployments remains future work. Finally, the full containerized stack (3 peers, 3 CouchDB instances, 1 orderer, 3 CAs, REST API gateway) consumes approximately 4.2 GB RAM at idle with CPU below 15% under sustained load, adequate for pilot infrastructure but potentially constraining for edge scenarios.

VI. CONCLUSION

This paper presented a distributed trust infrastructure for continuous cybersecurity certification within the COBALT framework. The core contribution is not a new Fabric primitive, but a reproducible automation pattern that operationalizes certification-oriented ledger deployment: a single declarative JSON configuration is transformed into a fully operational Hyperledger Fabric network in approximately two minutes, reducing error-prone manual configuration by two orders of magnitude. The architecture enforces data sovereignty through segregated channels and a hash-on-chain anchoring pattern, while a federated identity mapping layer and REST API gateway enable seamless integration with the broader COBALT ecosystem. Controlled benchmarks confirmed sustained write throughput of 30 TPS with 0.28 s average ledger latency, while

the full stack operates within modest resource constraints.

Future work includes semantic validation of evidence artifacts against certification schemas (e.g., CycloneDX, OSCAL) before anchoring, and migration to Fabric 3.x with BFT consensus for enhanced resilience [12]. The source code and deployment scripts will be released as open-source upon completion of the COBALT project, subject to consortium agreements.

ACKNOWLEDGEMENTS

This work has been produced with the support of the EU through the Horizon research and innovation program COBALT (grant agreement no. 101119602). Research was also partially supported by a 2024 Leonardo Grant for Scientific Research and Cultural Creation, BBVA Foundation. The Foundation takes no responsibility for the opinions, statements and contents of this project, which are entirely the responsibility of its authors. This work has been also funded by the European Union's NextGenerationEU, as part of the Recovery, Transformation, and Resilience Plan, supported by Spanish INCIBE (6G-SOC project).

REFERENCES

- [1] European Parliament and Council of the European Union, "Regulation (EU) 2024/2847 of 23 October 2024 on horizontal cybersecurity requirements for products with digital elements and amending Regulations (EU) No 168/2013 and (EU) 2019/1020 and Directive (EU) 2020/1828 (Cyber Resilience Act)," *Official Journal of the European Union*, OJ L, 2024/2847, 20 Nov. 2024. [Online]. Available: <https://eur-lex.europa.eu/eli/reg/2024/2847/oj/eng>
- [2] European Parliament and Council of the European Union, "Regulation (EU) 2019/881 of 17 April 2019 on ENISA (the European Union Agency for Cybersecurity) and on information and communications technology cybersecurity certification and repealing Regulation (EU) No 526/2013 (Cybersecurity Act)," *Official Journal of the European Union*, OJ L 151, 7 Jun. 2019. [Online]. Available: <https://eur-lex.europa.eu/eli/reg/2019/881/oj/eng>
- [3] European Parliament and Council of the European Union, "Directive (EU) 2022/2555 of 14 December 2022 on measures for a high common level of cybersecurity across the Union, amending Regulation (EU) No 910/2014 and Directive (EU) 2018/1972, and repealing Directive (EU) 2016/1148 (NIS 2 Directive)," *Official Journal of the European Union*, OJ L 333, 27 Dec. 2022. [Online]. Available: <https://eur-lex.europa.eu/eli/dir/2022/2555/oj/eng>
- [4] R. Neisse, J. L. Hernandez-Ramos, S. N. Matheu-García, G. Baldini, A. Skarmeta, V. Siris, D. Lagutin, and P. Nikander, "An interledger blockchain platform for cross-border management of cybersecurity information," *IEEE Internet Computing*, vol. 24, no. 3, pp. 19–29, 2020, doi: 10.1109/MIC.2020.3002423.
- [5] N. K. Tran, M. A. Babar, and A. Walters, "A framework for automating deployment and evaluation of blockchain networks," *Journal of Network and Computer Applications*, vol. 206, p. 103460, 2022, doi: 10.1016/j.jnca.2022.103460.
- [6] I. Zikos, A. Sendros, G. Drosatos, and P. S. Efraimidis, "HFabD+M: A web-based platform for automated Hyperledger Fabric deployment and management," in *2022 IEEE 1st Global Emerging Technology Blockchain Forum: Blockchain & Beyond (iGETblockchain)*, Irvine, CA, USA, 7–11 Nov. 2022, pp. 1–6, doi: 10.1109/iGETblockchain56591.2022.10087061.
- [7] Hyperledger Fabric Documentation, "Membership Service Provider (MSP)," Hyperledger Fabric v2.5. [Online]. Available: <https://hyperledger-fabric.readthedocs.io/en/release-2.5/membership/membership.html> Accessed: Feb. 2026.
- [8] Hyperledger Labs, "Minifabric: Do fabric network the right and easy way," GitHub repository. [Online]. Available: <https://github.com/hyperledger-labs/minifabric> Accessed: Feb. 2026.
- [9] Hyperledger Labs, "Fablo," GitHub repository. [Online]. Available: <https://github.com/hyperledger-labs/fablo> Accessed: Feb. 2026.
- [10] National Institute of Standards and Technology (NIST), "OSCAL (Open Security Controls Assessment Language)," NIST. [Online]. Available: <https://pages.nist.gov/OSCAL/> Accessed: Feb. 2026.
- [11] Hyperledger Foundation, "Hyperledger Caliper," GitHub repository. [Online]. Available: <https://github.com/hyperledger/caliper> Accessed: Apr. 2026.
- [12] Hyperledger Fabric Project, "v3.0.0 Release Notes," GitHub Releases, Sep. 17, 2024. [Online]. Available: <https://github.com/hyperledger/fabric/releases/tag/v3.0.0> Accessed: Feb. 2026.

LLM-based Classification of CVEs for Vulnerability Analysis in Medical IT Systems

Pere Vidiella^{1,2}, Pere Tuset-Peiró^{2,4}, Josep Pegueroles¹, Michael Pilgermann³

¹Universitat Politècnica de Catalunya, Barcelona, Spain,
{pere.vidiella, josep.pegueroles}@upc.edu

²TecnoCampus - Universitat Pompeu Fabra, Mataró, Spain,
{ptuset}@tecnocampus.cat

⁴Universitat Oberta de Catalunya, Barcelona, Spain,
{peretuset}@uoc.edu

³Brandenburg University of Applied Sciences, Brandenburg, Germany,
{michael.pilgermann}@th-brandenburg.de

Abstract—The digitalization of healthcare systems increases exposure to cybersecurity incidents. CVE records are widely used to identify vulnerabilities, but they often lack structured, actionable information for effective decision-making. Manual augmentation is impractical due to the rapid growth of CVEs. This paper evaluates the use of LLMs to classify and analyze CVEs in the medical IT domain. We propose a framework where LLMs process structured JSON inputs to categorize vulnerabilities by medical system context, affected components, and MITRE ATT&CK tactics. Results show that domain-specific prompting enables fine-grained and actionable classification, improving vulnerability prioritization. This approach enhances standard CVE records and supports better risk assessment in healthcare environments.

Index Terms—Medical IT systems, LLM, CVE, CVSS, PACS, DICOM, HL-7, MITRE ATT&CK.

Tipo de contribución: *Investigación en desarrollo*

I. INTRODUCTION

The digital transformation of healthcare has led to an increasing reliance on medical IT systems, making their security critical for ensuring patient safety and service continuity. The CVE (Common Vulnerabilities and Exposures) system [1] provides a standardized framework for identifying and cataloging publicly known vulnerabilities. However, the rapid growth in reported CVEs, 38% between 2023 and 2024, renders manual analysis and prioritization increasingly unscalable, particularly in complex medical environments.

While our previous work focused on assessing the state of cybersecurity in medical IT systems using OSINT tools [2], this paper introduces a novel, LLM-based framework for domain-specific classification and analysis. Moving beyond general CVSS scoring or CNA-oriented patterns, our approach performs a multi-dimensional augmentation of CVE data using structured prompts, enabling the model to:

- 1) **Filter** vulnerabilities based on their direct relevance to medical IT systems.
- 2) **Identify** specific affected vendors and products within the healthcare sector.
- 3) **Categorize** vulnerabilities across various medical system layers.
- 4) **Map** identified vulnerabilities to corresponding MITRE ATT&CK tactics.

II. OVERVIEW OF CYBERSECURITY CONCEPTS AND MEDICAL IT SYSTEMS

Cybersecurity analysis is based on two core references: the CVE catalog and the MITRE ATT&CK framework. The CVE (Common Vulnerabilities and Exposures) catalog provides standardized identifiers for publicly disclosed vulnerabilities, including descriptions, affected products, and severity scores based on CVSS. The MITRE ATT&CK framework models adversarial behavior in terms of tactics (attack objectives) and techniques (methods), enabling mapping of vulnerabilities to potential attack scenarios.

In turn, medical IT systems are classified into functional categories derived from healthcare standards and architectures [3], [4], [5], [6], [7], [8]:

- 1) **Data identity and management systems:** Administrative systems managing patient data (e.g., HIS, EMR, EHR).
- 2) **Departmental information systems:** Clinical workflow systems (e.g., RIS, LIS, PIS).
- 3) **Data generation systems:** Medical imaging and diagnostic devices (e.g., CT, MRI, PET, X-ray).
- 4) **Storage and archiving systems:** Systems for storing and retrieving clinical data (e.g., PACS, VNA).
- 5) **Interoperability systems:** Standards enabling data exchange between systems (e.g., DICOM, HL7).

This approach supports mapping CVEs to their operational role in healthcare environments, enabling more meaningful impact assessment, while excluding general IT communication systems whose vulnerabilities are not domain-specific.

III. METHODOLOGY

This section describes the construction of the CVE dataset, the LLM setup, and the classification methodology. All artifacts are available at: <https://github.com/grec-tcm/jnic2026>.

A dataset of medical-related CVEs is built through a keyword-based search on the CVE database (<https://www.cve.org/>). A product-based approach was discarded due to poor scalability. Keywords derived from medical IT systems (e.g., *medical*, *hospital*, *DICOM*, *PACS*, *EHR*, *HL7*) were used to retrieve relevant entries, yielding 1163 CVEs. After deduplication, the dataset contains 1097 unique entries. CVE

records were retrieved in JSON format from both the MITRE and NVD APIs to ensure data completeness, as inconsistencies were observed across sources (e.g., missing or multiple CVSS versions). The combined dataset provides enriched vulnerability information for subsequent analysis.

Then an LLM performs a multi-stage classification of CVEs. First, a binary classification filters vulnerabilities relevant to medical IT systems, reducing false positives introduced by keyword-based retrieval. Second, relevant CVEs are categorized across multiple dimensions:

- Medical system category (as defined in Section II)
- Affected component (hardware, firmware, OS, software, library)
- MITRE ATT&CK tactic (from initial access to data collection)

This multi-dimensional classification provides contextualized vulnerability insights, enabling mapping from technical flaws to operational impact and adversarial behavior.

Experiments were conducted locally using a workstation with an AMD Ryzen 9 5950X CPU, 32 GB RAM, and an NVIDIA RTX 5070 GPU (12 GB VRAM). We used the Gemma3 12B model executed via `ollama`. Runtime optimizations included a 40k token context window, 4-bit KV-cache quantization, flash attention, and parallel execution with two workers. The temperature was set to 0 to ensure deterministic outputs.

Regarding the LLM prompt, a standardized template is used, combining explicit classification instructions with CVE records from MITRE and NVD. To ensure consistency, classification outputs are restricted to predefined categories, and a fixed JSON schema is enforced. Healthcare relevance is determined using a *primary-purpose* criterion, distinguishing clinical systems from general-purpose software, with additional rules to avoid misclassification of supporting tools (e.g., DICOM parsers). The prompt also requires justification of each classification decision and assigns MITRE ATT&CK tactics using a priority rule based on the earliest attack stage. This structured design improves consistency, interpretability, and reproducibility of results.

IV. RESULTS

Figure 1 shows a the number of CVE vulnerabilities that have been discovered and reported per year. As observed, there is a strong growth trend, increasing from 19 CVEs (2004–2010) to 298 in 2025, highlighting the increasing burden on vulnerability analysis.




Figure 1: Number of CVE vulnerabilities that have been discovered and reported per year.

Figure 2 presents the CVE severity distribution based on their CVSS value and category. Notably, in the medical domain 48.4% of CVEs are classified as high or critical (30.9% high and 17.5% critical), indicating a significant proportion of impactful vulnerabilities.




Figure 2: CVE distribution according to their CVSS value and category. Background colors (green, yellow, orange and red) represent CVSS severity (low, medium, high and critical).

Relevance filtering: The LLM filters non-medical CVEs, removing 11.3% (124 entries), as shown in Figure 3 and Table I. Manual validation confirms strong performance, achieving 92.0% accuracy and 95.6% F1-score (Tables II and III).




Figure 3: CVE distribution according to their CVSS value and category after filtering for medical relevance. Orange bars indicate CVEs that have been filtered out by the LLM.

Table I: Distribution of medical-related vs. non-medical related CVEs according to their CVSS value.

Value	Med (N)	Med (%)	Non-Med (N)	Non-Med (%)
0	0	0.0%	0	0.0%
1	1	0.1%	0	0.0%
2	8	0.7%	3	0.3%
3	13	1.2%	3	0.3%
4	58	5.3%	13	1.2%
5	167	15.2%	29	2.6%
6	244	22.2%	27	2.5%
7	178	16.2%	24	2.2%
8	129	11.8%	8	0.7%
9	149	13.6%	17	1.5%
10	26	2.4%	0	0.0%
Total	973	88.7%	124	11.3%

System-level classification: Figure 4 and Table IV show that vulnerabilities are unevenly distributed. Identity/management and data generation systems contain the highest number

Table II: Classification Summary and Error Distribution.

Category	Count	Percentage
True Positives (TP)	954	86.96%
True Negatives (TN)	55	5.01%
False Positives (FP)	19	1.73%
False Negatives (FN)	69	6.29%
Total	1097	100%

Table III: Detection Performance Metrics.

Metric	Value
Precision	98.05%
Recall (Sensitivity)	93.25%
F1-score	95.60%
Accuracy	92.00%

of CVEs, while high and critical vulnerabilities appear across all categories, with storage systems showing a concentration of high-severity issues.

Table IV: Percentage of CVEs according to their CVSS category (low, medium, high and critical) and healthcare system category.

Category	Low (%)	Med (%)	High (%)	Crit (%)
Data Identity & Management Systems	1.4%	53.4%	27.3%	18.0%
Departmental Information Systems	3.7%	52.3%	31.2%	12.8%
Data Generation Systems	4.5%	45.9%	29.1%	20.5%
Storage & Archiving Systems	1.1%	37.8%	43.3%	17.8%
Interoperability Systems	0.0%	33.3%	45.8%	20.8%

Component classification: Figure 5 and Table V show that most vulnerabilities affect software and firmware. However, the LLM does not reliably distinguish operating systems and libraries from software.

Table V: Percentage of CVEs according to their category (low, medium, high and critical) and the affected component.

Component	Low (%)	Med (%)	High (%)	Crit (%)
Hardware	0.0%	50.0%	30.0%	20.0%
Firmware	3.9%	48.5%	27.2%	20.4%
Operating System	-	-	-	-
Software	2.1%	48.1%	32.1%	17.7%
Library	-	-	-	-

ATT&CK mapping: Figure 6 and Table VI show that vulnerabilities are mainly associated with early attack stages (e.g., *Initial Access*, *Execution*, *Credential Access*). Later stages such as *Impact*, although less frequent, still include high-severity vulnerabilities.

Table VI: Percentage of CVEs according to their CVSS category (low, medium, high and critical) and the MITRE ATT&CK framework.

ATT&CK Phase	Low (%)	Med (%)	High (%)	Crit (%)
Reconnaissance	-	-	-	-
Resource Development	-	-	-	-
Initial Access	2.3%	46.5%	30.6%	20.6%
Execution	2.1%	67.7%	29.2%	1.0%
Persistence	-	-	-	-
Privilege Escalation	0.0%	12.5%	62.5%	25.0%
Defense Evasion	-	-	-	-
Credential Access	0.0%	33.3%	55.6%	11.1%
Discovery	-	-	-	-
Lateral Movement	-	-	-	-
Collection	-	-	-	-
Command and Control	-	-	-	-
Exfiltration	-	-	-	-
Impact	3.3%	46.7%	50.0%	0.0%

The results demonstrate that LLMs can effectively automate domain-specific CVE classification and enrich vulnerability

analysis. However, limitations remain, including occasional misclassifications due to ambiguous descriptions and difficulty in fine-grained component categorization. Confidence scores were also found to be unreliable. Future work should explore improved prompting strategies and ensemble approaches.

V. CONCLUSIONS AND FUTURE WORK

This work demonstrates the viability of utilizing LLM models to automate the triage and multidimensional classification of CVEs within the medical IT domain. Our framework successfully filtered healthcare-relevant vulnerabilities with an accuracy of 92.00% and a 95.60% F1-score, as well as effectively mapping them to specific functional medical systems and MITRE ATT&CK adversarial phases. This automated augmentation provides critical operational context often missing from standard CVE records, revealing that data identity systems and data generation equipment are frequent targets, predominantly during the initial access and execution stages of an attack. However, our analysis also highlights notable limitations in off-the-shelf LLM reasoning, including difficulties in granular component-level categorization (such as distinguishing between operating systems and libraries), occasional contextual hallucinations, and the unreliability of the model's self-reported confidence scores.

To address these limitations and further advance automated vulnerability assessment, future work will focus on comparative evaluations of diverse LLM architectures and parameter scales to determine the optimal configurations for domain-specific categorization. We also plan to explore ensemble-based classification methodologies, aggregating outputs from multiple LLM models to mitigate individual hallucinations and enhance overall diagnostic reliability. Additionally, refining context-aware prompting strategies to balance strict domain-specific vocabulary with the scalability of baseline models remains a primary objective. Finally, extending our framework to include deeper software dependency-chain analysis will help capture complex, indirect vulnerabilities, ultimately ensuring a more robust and comprehensive security posture for critical healthcare infrastructures.

ACKNOWLEDGMENTS

This project is carried out within the framework of the Recovery, Transformation, and Resilience Plan, funded by the EU Next Generation funds, under the auspices of the INCIBE cybersecurity chair named CARISMATICA.

REFERENCES

- [1] Walkowski, Michał et al., "Vulnerability Management Models Using a Common Vulnerability Scoring System," vol. 11, no. 18, p. 8735. [Online]. Available: <https://www.mdpi.com/2076-3417/11/18/8735>
- [2] Tuset-Peiró, Pere et al., "Assessing cybersecurity of Internet-facing medical IT systems in Germany & Spain using OSINT tools," in *Actas de las X Jornadas Nacionales de Investigación en Ciberseguridad (JNIC)*, Zaragoza, Spain, 2025, pp. 190–197.
- [3] HL7 International, "HL7 Version 2 Product Suite," https://www.hl7.org/implement/standards/product_brief.cfm?product_id=185, 2023, accessed: 2026-02.
- [4] *ISO/HL7 10781:2015 Health Informatics — Electronic Health Record System Functional Model (EHR-S FM)*, International Organization for Standardization Std., 2015, international Standard.
- [5] *ISO 12967:2012 Health Informatics — Service Architecture (HISA)*, International Organization for Standardization Std., 2012, international Standard.
- [6] DICOM Standards Committee, "Digital Imaging and Communications in Medicine (DICOM) Standard," <https://www.dicomstandard.org>, 2023, accessed: 2026-02.




Figure 4: CVE distribution according to their CVSS value (0-10) and category (low, medium, high and critical), and the medical IT system category (Data Identity & Management, Departmental Information Systems, Data Generation Systems, Storage & Archiving Systems, and Interoperability Systems).




Figure 5: CVE distribution according to their CVSS value (0-10) and category (low, medium, high and critical), and the affected component (i.e., *Hardware*, *Firmware*, *Operating System*, *Software*, and *Library*).




Figure 6: CVE distribution according to their CVSS value (0-10) and category (low, medium, high and critical), and the MITRE ATT&CK framework.

[7] E. H. Shortliffe and J. J. Cimino, *Biomedical Informatics: Computer Applications in Health Care and Biomedicine*, 4th ed. Springer, 2014.

[8] H. K. Huang, *PACS and Imaging Informatics: Basic Principles and Applications*, 2nd ed. Wiley-Blackwell, 2010.

A review of: Decentralizing Photo Forensics for Public and Verifiable Trust

Mauro Clavijo-Herrera
Universitat Rovira i Virgili
Tarragona, Spain
mauro.clavijo@urv.cat

Rolando Trujillo-Rasua
Universitat Rovira i Virgili
Tarragona, Spain
rolando.trujillo@urv.cat

Carles Anglés-Tafalla
Universitat Rovira i Virgili
Tarragona, Spain
carles.angles@urv.cat

Abstract—As advanced editing tools and Generative AI become more powerful and accessible, it is getting harder to trust digital photos as reliable evidence. Many current forensic approaches force users to pick between relying on centralized authorities (like C2PA) or using permissioned blockchains that limit who can independently verify the data.

In this work, we present an endorsement-based image forensics system built on a public blockchain. The system uses hybrid encryption and a flexible validation framework that can handle both reproducible functions and Zero-Knowledge proofs. This design ensures that image transformations can be traced, verified, and kept confidential when needed. Instead of depending on a single central authority, we propose a decentralized trust model where users judge the reliability of evidence based on a collection of endorsements from different parties. Experiments on an Ethereum testnet show that the approach is cost-effective, with low gas costs for the core operations.

Index Terms—Blockchain, photo forensics, confidentiality, transformation validation, zero-knowledge proofs.

Contribution type: Research already published [1].

I. INTRODUCTION

Digital forensics is highly dependent on the ability to collect, preserve and analyze evidence while maintaining its technical integrity. However, the rapid advancement of Generative AI has made the manipulation of visual content trivial, raising serious concerns about whether digital evidence can be trusted in legal and journalistic settings.

To address this, the concept of authenticity must extend beyond static integrity to include *traceability*. A user should be able to verify the entire history of an image, from the source camera to the final edited version. Although standards like C2PA [3] provide cryptographic signing of metadata, they rely on centralized Public Key Infrastructures and do not inherently verify the *correctness* of a transformation (e.g., proving that a blur operation only obscured a face and did not alter the background).

Furthermore, there is a critical tension between transparency and confidentiality. In scenarios like "Human Flesh Search" (collaborative online investigations) [2] or sensitive criminal cases, revealing the original raw image to verify a transformation might expose protected witnesses or sensitive data.

Our work proposes a solution that leverages the immutability of public blockchains without sacrificing privacy. We introduce a system where:

- 1) Transformations are explicitly validated by third parties (validators).
- 2) Confidentiality is preserved via hybrid encryption and Zero-Knowledge (ZK) proofs.

- 3) Trust is decentralized, allowing end-users to define their own criteria for accepting evidence.

II. SYSTEM DESIGN

A. Actors and Roles

The system models the forensic lifecycle using four primary roles:

- **Certified Cameras (C):** Tamper-proof devices that sign the initial capture (p_0) with a unique private key (sk_c). This function as the hardware-based root of trust.
- **Owners (O):** Users who register original images. They define access control policies stored off-chain.
- **Editors (E):** Users who apply transformation functions (f) to images. They must prove the validity of their edits to maintain the chain of custody.
- **Validators (V):** Third parties who endorse transformations. They can be incentivized economically or through a reputation system.

B. Workflow and Hybrid Encryption

We employ off-chain storage combined with a hybrid encryption scheme to operate on a public blockchain (such as Ethereum) while maintaining the privacy of image content.

1) *Registration:* When an owner registers an image p_0 , a random symmetric key k is generated to encrypt the image ($enc(p_0, k)$). This key k is then asymmetrically encrypted using the public keys of authorized users (e.g., specific validators or investigators). The encrypted payload is stored in a Decentralized Database (DDB), while the hash $h(p_0)$ and the camera's signature are anchored on the blockchain.

2) *Transformation:* An editor retrieves and decrypts p , applies a function f to generate p' , and uploads the encrypted result. Crucially, the editor publishes metadata to the blockchain allowing for validation. This metadata depends on the chosen validation mode.

C. Flexible Validation Modes

A key contribution of this system is the ability to select the validation method per transformation.

- **Reproducible Validation:** The editor publishes the function f . Validators with access rights decrypt the original p , compute $f(p)$, and verify that the result matches the hash on the chain $h(p')$. This provides the highest level of verification, but requires revealing p to the validators.
- **Zero-Knowledge Validation:** The editor computes a ZK-proof π asserting that they know a pair (p, p') such that $p' = f(p)$, without revealing the images. Validators

verify π on-chain. This mode is essential for privacy-preserving forensics [4].

- **Unverifiable:** Used when the transformation cannot be mathematically proven or reproduced (e.g., manual artistic retouching), serving only as a log of authorship.

III. TRUST AND INCENTIVES

A. Trust Function

Unlike centralized systems that enforce a binary “trusted/untrusted” status based on a root certificate, our system calculates trust dynamically. We define trust as a logical formula over a provenance chain $\tau = t_1 \dots t_n$:

$$Trust(\tau) = \bigwedge_{i=1}^n Trust(t_i) \quad (1)$$

A transformation t_i is considered trusted if it satisfies user-defined properties, such as reproducibility or the number of endorsements. This allows the system to adapt to different circumstances (e.g., a court of law).

B. Validator Motivation

To ensure active participation, the system supports two incentive mechanisms:

- 1) **Economic Rewards:** Validators can receive micropayments for correct endorsements.
- 2) **Reputation:** A public score tracks successful endorsements, allowing users to filter validations based on the reputation of the signer.

IV. SECURITY ANALYSIS

The system is evaluated under the Dolev-Yao model: an adversary who acts as the network itself, capable of reading and modifying any data in transit. However, the attacker is computationally bounded and cannot decrypt messages without the corresponding key, following the ‘perfect cryptography’ assumption. The system ensures:

- **Integrity:** The blockchain creates an immutable timeline. Any alteration to the off-chain image p results in a hash mismatch with the on-chain record.
- **Non-Repudiation:** All transactions are signed. An editor cannot deny applying a transformation, and a certified camera cannot be spoofed without extracting its physical key.
- **Conditional Confidentiality:** By encrypting k only for authorized public keys, the system ensures that even if the DDB is public, the visual evidence remains inaccessible to unauthorized parties.
- **Resilience to DoS:** High gas costs for writing to the blockchain naturally deter flooding attacks. Malicious validators are mitigated by the reputation system, which disregards endorsements from low-trust entities.

V. EMPIRICAL EVALUATION

A. Experimental Setup

The smart contracts were implemented in Solidity and deployed on a local Ganache blockchain simulator to measure gas consumption. The tests were performed on a standard consumer laptop (3th Gen Intel(R) Core(TM) i7-13620H, 16GB of LPDDR5 RAM).

Table I
GAS USAGE FOR CORE CONTRACT OPERATIONS

Operation	Gas Used
Contract Deployment	634975
storeImage	51750
confirmValidation	92430

B. Gas Cost Analysis

To evaluate the economic feasibility of our system, we analyzed the gas consumption of its three most frequent operations relative to a standard Ethereum transaction. Although the base cost for a simple transfer is 21,000 gas, our implementation remains efficient by using the blockchain primarily for metadata anchoring. Specifically, registering an image costs approximately 2.5 times the base transaction, while endorsing a transformation requires roughly 4.4 times that amount. This confirms that our architecture is well-suited for cost-effective public deployment. Table I summarizes the associated costs.

VI. CONCLUSION AND FUTURE WORK

This work presents a robust framework for decentralized image forensics. By decoupling image storage (DDB) from verification (Blockchain) and utilizing hybrid encryption, we achieve a balance between the transparency required for public trust and the confidentiality required for sensitive investigations. The system improves upon prior art by offering granular, per-transformation validation modes (Reproducible and ZK). Future work will focus on implementing shared encryption schemes (e.g. Attribute-Based Encryption) to allow dynamic groups of validators to access evidence.

ACKNOWLEDGMENT

The current work is supported by the projects “HERMES” from INCIBE, PROVTOPIA (PID2023-150098OB-I00), SECURING/DATA (PID2021-125962OB-C32), and SAFE/DATA (PID2024-156914OB-C42), all funded by MCIN/AEI/10.13039/501100011033/FEDER, UE; and by the grant 2021SGR 00115 from the Government of Catalonia. Rolando Trujillo-Rasua is also funded by a Ramon y Cajal grant (REF: RYC2020-028954-1). Mauro Clavijo is supported by a Martí i Franquès grant (REF: 2023PMF-PIPF-46).

REFERENCES

- [1] Clavijo-Herrera, M., Trujillo-Rasua, R., & Anglés-Tafalla, C. (2025). Decentralizing photo forensics for public and verifiable trust. *Proceedings of the 24th IEEE International Conference on Trust, Security and Privacy in Computing and Communications (TrustCom)*, 878–885. <https://doi.org/10.1109/Trustcom66490.2025.00102>
- [2] Chang, L. Y., & Zhu, J. (2020). Taking justice into their own hands: Predictors of netilantism among cyber citizens in Hong Kong. *Frontiers in Psychology*, 11, 556903.
- [3] Coalition for Content Provenance and Authenticity. (2025). *C2PA specification v2.2*. <https://c2pa.org/specifications/specifications/2.2/>
- [4] Kang, D., Hashimoto, T., Stoica, I., & Sun, Y. (2022). ZK-IMG: Attested images via zero-knowledge proofs to fight disinformation (ArXiv preprint arXiv:2211.04775).
- [5] Li, X., Wei, L., Wang, L., Ma, Y., Zhang, C., & Sohail, M. (2022). A blockchain-based privacy-preserving authentication system for ensuring multimedia content integrity. *International Journal of Intelligent Systems*, 37(5), 3050–3071.
- [6] Lusetti, M., Salsi, L., & Dallatana, A. (2020). A blockchain based solution for the custody of digital files in forensic medicine. *Forensic Science International: Digital Investigation*, 35, 301017.

Satellite-enabled extension of QKD Networks for operation in remote environments

Aitor Brazaola-Vicario* and Oscar Lage*

*TECNALIA, Basque Research and Technology Alliance (BRTA), 48160 Derio, Spain
{aitor.brazaola, oscar.lage}@tecnalia.com

Abstract—Quantum Key Distribution (QKD) enables the establishment of symmetric keys with information-theoretic confidentiality grounded in quantum mechanics, but its deployment typically requires dedicated optical infrastructure and specialised hardware, limiting its use in remote, mobile, or time-constrained scenarios. In parallel, low-Earth-orbit satellite constellations increasingly provide IP connectivity in regions without terrestrial networks, although these channels remain untrusted.

This work proposes a lightweight hybrid protocol to extend the operational reach of QKD networks into disconnected environments by transporting freshly generated QKD keys over satellite internet links. Confidentiality is ensured through one-time-pad protection derived from previously shared QKD material, while a deterministic and synchronised key-update mechanism prevents secret reuse by ratcheting pre-shared entropy forward. The approach is evaluated through a simulation of 1500 rounds seeded with real QKD key material. Statistical analysis of the derived keys using entropy, avalanche, and bit-balance metrics shows near-ideal randomness properties, supporting the protocol as a practical bridge towards broader QKD deployment in tactical and remote contexts.

Index Terms—QKD, Tactical Scenarios, Satellite Internet Links, Key Derivation Functions, One-Time Pad, Key Ratcheting

Tipo de contribución: *Investigación original*

I. INTRODUCTION

Quantum Key Distribution (QKD) enables key establishment based on quantum mechanics rather than computational assumptions, producing symmetric keys via quantum exchange and authenticated classical reconciliation [1]. While suitable for high-assurance scenarios, its deployment is limited by the need for dedicated optical infrastructure and specialised hardware [2].

In contrast, LEO satellite constellations provide practical IP connectivity in remote and rapidly deployed environments, with demonstrated large-scale use [3]. Although offering usable latency and throughput, they exhibit higher variability and must be treated as untrusted and potentially disruptable channels [4].

We propose a hybrid protocol where a pre-shared QKD secret is expanded into per-round OTP masks using a KDF [5]. Fresh QKD keys are transported encrypted under these masks, while a ratcheting mechanism refreshes the shared state to prevent reuse and enable long-lived operation.

The quality of the protocol is evaluated through simulation based on a real QKD pre-shared key, using 1500 rounds and multiple cryptographic quality metrics. The remainder of the paper is structured as follows. Section II reviews related work. Section III specifies the protocol and security assumptions. Section IV reports experimental results and discusses limitations. Section V concludes and outlines future work.

II. RELATED WORK

QKD has been demonstrated in metropolitan-scale and backbone-like networks using trusted-node paradigms and heterogeneous link integration, as illustrated by SECOQC and the Tokyo QKD Network [6], [7]. These efforts established practical architectures for integrating QKD into deployable systems, but remain constrained by optical reach and by the trust assumptions required when intermediate nodes process key material.

Satellite-based QKD provides an alternative by enabling long-distance key distribution through space-to-ground optical links. Demonstrations with the *Micius* satellite confirmed the feasibility of global-scale quantum networking [8]. However, this approach requires specialised payloads, optical terminals, and precise tracking, leading to significant cost and operational complexity compared to commodity satellite Internet.

Hybrid approaches instead combine QKD-derived entropy with classical cryptographic mechanisms to improve deployability. While OTP offers perfect secrecy under strict conditions [9], its requirement for fresh, non-reused keys equal in length to the message limits practicality. KDFs, particularly HKDF, provide a standard way to expand secret material into multiple context-bound keys [5], [10], and ratcheting constructions allow evolving key material over time to avoid reuse and support forward secrecy [11].

From an operational perspective, LEO satellite connectivity enables rapid deployment in remote or disconnected environments, though with latency variability and packet loss [12]. These properties motivate the need for mechanisms addressing message ordering, replay protection, and resynchronisation.

Building on these elements, this work proposes a deployable protocol that assumes QKD availability only during an initial setup phase, uses satellite Internet as an untrusted transport channel, and maintains a deterministic, synchronised evolution of pre-shared key material to prevent reuse.

III. PROPOSED APPROACH

To anchor the evaluation in realistic conditions, we consider a commercial QKD system manufactured by ID Quantique, comprising a transmitting unit and a receiving unit implementing the Coherent-One-Way (COW) protocol [13]. The laboratory deployment is located at TECNALIA facilities within the Bizkaia Technology Park and operates over optical fibre between two buildings separated by approximately one kilometre. Distilled QKD keys generated by the device are used in two distinct roles:

- **Pre-deployment bootstrapping secret** (psk_0). A 256-bit key (or concatenation of multiple keys) exchanged

via QKD during a preparatory phase when the remote node can be co-located or otherwise optically connected.

- **Operational QKD keys** ($k_{q,i}$). Fresh keys generated within the fixed QKD infrastructure (e.g., within a national QKD backbone) that must be securely provisioned to a remote node with no optical connectivity.

A. Threat model and design goals

The protocol is designed for remote and tactical settings where the satellite link must be assumed untrusted. The adversary is assumed capable of:

- **Passive observation** of all satellite-carried ciphertexts and metadata (timing, sizes, endpoints).
- **Active manipulation** including packet drops, reordering, replay, and injection of malformed messages.

Physical compromise of endpoints is out of scope for the confidentiality of already-consumed OTP masks, but the protocol aims to reduce long-term damage by evolving key state (ratcheting). The key design goals are:

- **Confidentiality of transported QKD keys** over satellite IP channels.
- **Strict avoidance of secret reuse** in OTP masks and in state evolution.
- **Operational simplicity** with minimal protocol overhead and clear state variables.
- **Robustness to link instability** through explicit indexing and optional re-synchronisation hooks.

B. Key derivation function and parameters

A Key Derivation Function (KDF) transforms high-entropy secret material into derived keys suitable for cryptographic use. We use HKDF-SHA256 [10] with:

- **Input Keying Material (IKM)**: the current pre-shared state psk_i .
- **Info binding**: round-indexed context strings (e.g., $otp-i$, $ratchet-i$) to enforce key separation.
- **Salt**: omitted, consistent with guidance when IKM has high entropy and is not attacker-controlled.
- **Output length**: 256 bits (32 bytes).

The security of this derivation relies on standard assumptions for HMAC and SHA-256 in HKDF usage, and aligns with generic KDF recommendations [5]. In addition, this work evaluates output quality using statistical metrics, while these tests cannot prove security, they provide practical confidence that the derivation does not introduce bias or structural artefacts.

C. Protocol description

Figure 1 depicts the protocol at a high level. Two parties are involved:

- **Trusted Node (TN)**: connected to a QKD network, capable of generating fresh QKD keys $k_{q,i}$.
- **Remote Trusted Node (RN)**: disconnected from optical infrastructure, reachable only via satellite IP.

At round i , both parties maintain the same pre-shared state $psk_i \in \{0, 1\}^{256}$. The TN derives an OTP mask:

$$otp_i = \text{HKDF}(psk_i, \text{info} = \text{otp}-i, L = 256),$$

encrypts the fresh QKD key:

$$ctk_i = k_i \oplus otp_i,$$

and transmits $\langle i, ctk_i \rangle$ over the satellite link. On reception, RN recomputes otp_i , recovers k_i by XOR, and stores it in a protected key buffer for subsequent symmetric cryptographic use.

To prevent reuse of psk_i and derived material, both parties update the pre-shared state via a ratchet step:

$$psk_{i+1} = \text{HKDF}(psk_i \parallel k_i, \text{info} = \text{ratchet}-i, L = 256).$$

This update consumes fresh entropy (the transported QKD key) and binds it into the evolving state. The concatenation $psk_i \parallel k_i$ ensures that even if psk_i were ever exposed after round i , subsequent states remain computationally hard to reconstruct without knowledge of k_i .

D. Flow diagram for implementation

For clarity, Figure 2 provides a flow diagram that can be mapped directly to implementation steps. The explicit round counter i is essential to ensure both ends derive the same otp_i , and detect replays or out-of-window messages.

IV. EXPERIMENTAL SETUP AND DISCUSSION

To assess the cryptographic quality of the derived material in conditions representative of long-lived operation, we performed a simulation of 1500 rounds, seeded from a real QKD-derived pre-shared key psk_0 extracted from the commercial system. In each round:

- 1) A fresh 256-bit key $k_{q,i}$ is generated (emulating a newly distilled QKD key within the fixed infrastructure).
- 2) otp_i is derived from the current state and used to encrypt $k_{q,i}$ into ct_i .
- 3) The receiver decrypts ct_i , stores $k_{q,i}$, and ratchets psk_{i+1} .
- 4) Metrics are computed over derived keys and associated transformations.

The evaluation focuses on three families of metrics:

- **Entropy (Shannon)**: assesses distributional unpredictability at the byte level.
- **Avalanche effect**: measures diffusion by quantifying output bit changes after a single-bit input perturbation.
- **Bit balance and binomial fit**: checks bias by comparing observed bit counts against the unbiased binomial model.

These metrics are complementary: balanced bit counts do not imply good diffusion, and high entropy alone does not guarantee resistance to structural weaknesses. Together, they provide practical assurance that the HKDF-based derivation behaves as expected under repeated rounds.

A. Entropy of derived keys

Figure 3 shows the histogram of Shannon entropy values computed for each 256-bit derived key. The distribution is concentrated close to the theoretical maximum of 5 bits per byte for uniformly random byte values, with an observed mean around 4.88 bits per byte. Minor spread is expected due to finite sample effects in 32-byte strings and does not indicate systematic bias. Practically, this result suggests that per-round derived masks behave as high-quality cryptographic material suitable for OTP-style usage, provided that the key schedule avoids reuse.




Figure 1. Global overview of the proposed protocol. A pre-shared QKD bootstrap key psk_0 is established before deployment. During operation, the central node derives an OTP mask otp_i from psk_i , encrypts a fresh QKD key k_{i+1} as ctk_{i+1} , and transports it over the satellite IP link. Both ends then ratchet the state to psk_{i+1} , ensuring that derived masks and states are never reused.




Figure 2. Implementation-oriented flow diagram. The explicit index i supports replay and ordering checks. Resynchronisation can be implemented as an operational procedure (e.g., exchanging the last confirmed index under an authenticated management channel).

B. Avalanche effect and diffusion

A desirable property of cryptographic derivation is that small input changes produce large, unpredictable output changes. Figure 4 shows the distribution of the avalanche effect obtained by flipping a single bit in the input and measuring the proportion of changed bits in the derived output. The mean is approximately 50.02%, with most observations



Figure 3. Histogram of Shannon entropy per derived key (256 bits). The dashed line marks the mean. Values clustered near 5 bits per byte indicate near-uniform byte distributions at the granularity observed.

falling near the 45–55% range. This behaviour is consistent with a strong diffusion effect expected from well-designed hash-based constructions.

Operationally, this matters because the protocol repeatedly derives otp_i and psk_{i+1} from evolving state. Strong diffusion reduces the risk that partial structure or correlations in psk_i could translate into predictable patterns in derived masks.

C. Bit distribution and binomial consistency

A basic sanity check for bias in binary keys is the distribution of zeros and ones. Figure 5 presents the histogram of bit counts for zeros and ones across all derived keys, overlaid with the theoretical binomial distribution $\text{Binomial}(n = 256, p = 0.5)$ and the expected value at 128.

The empirical distributions for zeros and ones are symmetric and closely follow the theoretical curve. Deviations near the tails are expected due to finite sampling and do not




Figure 4. Histogram of avalanche effect per derived key. The metric reports the percentage of output bits that change when a single input bit is flipped. Values concentrated around 50% indicate strong diffusion.

indicate systematic skew. In practical terms, this suggests that the derived masks are not exhibiting a bias that would reduce effective entropy or enable statistical distinguishability at the level tested.




Figure 5. Bit-count histograms per derived key (256 bits). Blue and orange bars show counts of zeros and ones, respectively. The green curve is the theoretical Binomial(256, 0.5) density, and the dashed line marks the expected value of 128. Close alignment supports the absence of detectable bias in bit balance.

D. Security discussion and limitations

The protocol provides confidentiality of transported QKD keys over an untrusted satellite IP channel using OTP-style encryption with per-round derived masks. Although masks are deterministically derived from high-entropy QKD material rather than independently generated, their statistical quality is comparable to cryptographic randomness used in practice.

Perfect secrecy requires uniformly random, single-use, and secret masks [9]. In this design, non-reuse is ensured through per-round derivation and ratcheting, while uniformity is supported empirically.

However, end-to-end information-theoretic security is not achieved, as key derivation and state evolution rely on computational assumptions. Security therefore depends on hash-based primitives such as HKDF, which, while widely analysed, provide computational guarantees [14].

Satellite channels also introduce practical concerns:

- **Replay and reordering:** mitigated via round indexing and windowing.
- **Availability:** the protocol does not prevent denial-of-service.
- **Endpoint security:** secure storage and zeroisation of masks are required.

The protocol serves as a pragmatic bridge, extending QKD-derived entropy to disconnected environments without requiring satellite QKD infrastructure.

V. CONCLUSION

This work presents a hybrid protocol that extends QKD network utility to remote environments using satellite Internet links as an untrusted transport for QKD-derived key material. One-time-pad masks are derived from pre-shared QKD entropy, while a ratcheting mechanism prevents secret reuse and enables continuous key provisioning. A 1500-round evaluation with real QKD material shows near-ideal entropy, avalanche behaviour around 50%, and bit distributions consistent with an unbiased binomial model.

Future work will focus on improving synchronisation, integrity, and authentication of transport messages using post-quantum cryptography, ensuring consistent key state evolution under message loss, reordering, or active interference, and increasing resilience in long-lived deployments.

REFERENCES

- [1] C. H. Bennett and G. Brassard, "Quantum cryptography: Public key distribution and coin tossing," *Theoretical Computer Science*, vol. 560, pp. 7–11, 2014, theoretical Aspects of Quantum Cryptography. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0304397514004241>
- [2] "Quantum communication infrastructure (euroqci) - european commission." [Online]. Available: https://hadea.ec.europa.eu/programmes/connecting-europe-facility/about/quantum-communication-infrastructure-euroqci_en
- [3] S. Exil, "Ucrania sostiene que el ejército ruso usa starlink a través de terceros países," *France 24*, 02 2024. [Online]. Available: <https://www.france24.com/es/europa/20240212-ucrania-dice-que-el-ej%C3%A9rcito-ruso-obtiene-acceso-al-servicio-starlink-a-trav%C3%A9s-de-terceros-pa%C3%ADses>
- [4] F. Michel, M. Trevisan, D. Giordano *et al.*, "A first look at Starlink performance," in *Proceedings of the ACM Internet Measurement Conference (IMC)*, 2022.
- [5] E. Barker, L. Chen, and R. Davis, "Recommendation for key-derivation methods in key-establishment schemes," 08 2020. [Online]. Available: <https://nvlpubs.nist.gov/nistpubs/SpecialPublications/NIST.SP.800-56Cr2.pdf>
- [6] M. Peev, C. Pacher, R. Alléaume *et al.*, "The SECOQC quantum key distribution network in vienna," *New Journal of Physics*, vol. 11, no. 7, p. 075001, 2009.
- [7] M. Sasaki, M. Fujiwara, H. Ishizuka *et al.*, "Field test of quantum key distribution in the Tokyo QKD network," *Optics Express*, vol. 19, no. 11, pp. 10 387–10 409, 2011.
- [8] S.-K. Liao, W.-Q. Cai, W.-Y. Liu *et al.*, "Satellite-to-ground quantum key distribution," *Nature*, vol. 549, no. 7670, pp. 43–47, 2017.
- [9] C. E. Shannon, "Communication theory of secrecy systems," *Bell System Technical Journal*, vol. 28, no. 4, pp. 656–715, 1949.
- [10] H. Krawczyk, "Cryptographic extraction and key derivation: The hkdf scheme," *LNCS*, vol. 6223, 2010. [Online]. Available: <https://eprint.iacr.org/2010/264.pdf>
- [11] T. Perrin and M. Marlinspike, "The double ratchet algorithm," Specification, 2025. [Online]. Available: <https://signal.org/docs/specifications/doublerratchet/>
- [12] R. Richter, V. Ververis, and V. Bajpai, "Breaking through the clouds: Performance insights into Starlink's latency and packet loss," in *Proceedings of IFIP Networking*, 2025.
- [13] D. Stucki, N. Brunner, N. Gisin *et al.*, "Fast and simple one-way quantum key distribution," *Applied Physics Letters*, vol. 87, no. 19, p. 194108, 11 2005. [Online]. Available: <https://doi.org/10.1063/1.2126792>
- [14] C. Adams, G. Kramer, S. Mister *et al.*, "On the security of key derivation functions," in *Information Security*, K. Zhang and Y. Zheng, Eds. Berlin, Heidelberg: Springer Berlin Heidelberg, 2004, pp. 134–145.

Desarrollo de un Simulador de Ciberengaño basado en Teoría de Juegos y el Marco MITRE Engage

Pedro Beltrán-López, Manuel Gil Pérez y Pantaleone Nespoli

Departamento de Ingeniería de la Información y las Comunicaciones, Universidad de Murcia, 30100 Murcia, España

Email: {pedro.beltranl, mgilperez, pantaleone.nespoli}@um.es

Resumen—En el contexto de la guerra cibernética asimétrica, las defensas estáticas tradicionales han demostrado ser insuficientes frente a adversarios persistentes y adaptables. El ciberengaño (Cyber Deception) emerge como un paradigma defensivo proactivo diseñado para alterar la asimetría, aumentar la incertidumbre del atacante y recopilar conocimiento para obtener inteligencia. Sin embargo, el despliegue de entornos de engaño efectivos sigue siendo complejo. Este artículo aborda dicha complejidad presentando el desarrollo de un simulador de código abierto basado en Teoría de Juegos de Información Imperfecta que integra operativamente el marco MITRE Engage. A diferencia de las abstracciones tradicionales, nuestra herramienta traduce tácticas de engaño reales en un juego estocástico donde el atacante opera bajo incertidumbre. La validación experimental en 125 escenarios demuestra que esta defensa adaptativa alcanza una tasa de éxito del 72 %, validando matemáticamente el mimetismo técnico para la automatización de la ciberdefensa activa.

Index Terms—Simulación, Defensa Activa, Ciberengaño, Teoría de Juegos, MITRE Engage, Hiperjuego

I. INTRODUCCIÓN

La ciberseguridad contemporánea se define por una asimetría estructural inherente: mientras que el defensor está obligado a proteger exitosamente la totalidad de su superficie de exposición, al atacante le basta con identificar y explotar una única vulnerabilidad para comprometer el sistema. Ante la demostrada insuficiencia de las defensas estáticas tradicionales y la rápida evolución de tácticas adversarias potenciadas por Inteligencia Artificial (IA), el *Ciberengaño* (Cyber Deception) [1] ha emergido como un cambio de paradigma imperativo hacia la defensa activa. Este enfoque proactivo transforma la red en un entorno dinámico y hostil mediante el despliegue estratégico de señuelos y artefactos falsos. Su objetivo no es únicamente interceptar la intrusión, sino manipular directamente la percepción del adversario, aumentando drásticamente su incertidumbre y forzando errores tácticos para agotar sus recursos cognitivos, económicos y temporales antes de que alcance sus objetivos reales.

Sin embargo, a pesar del evidente potencial estratégico del ciberengaño, su implementación sistemática y automatizada se enfrenta a una brecha crítica en el estado del arte. Por un lado, la *Teoría de Juegos* ha sido ampliamente utilizada para modelar estas interacciones, pero frecuentemente ofrece abstracciones matemáticas excesivamente simplificadas que asumen información perfecta o ignoran las limitaciones técnicas del mundo real [2]. Por otro lado, la industria ha desarrollado marcos operativos robustos como *MITRE Engage*

[3], los cuales estandarizan acciones de engaño pero carecen de los modelos formales necesarios para orquestar la toma de decisiones de manera dinámica, cuantificable y autónoma. Este trabajo aborda directamente dicha limitación presentando el diseño y desarrollo de un simulador que unifica la rigurosidad matemática de los modelos teóricos con la aplicabilidad técnica de los estándares de la industria. En concreto, las contribuciones principales de este artículo son:

- **Integración de MITRE Engage:** Metodología para mapear acciones tácticas en variables de juego estocásticas, dotando de realismo operativo al modelo matemático.
- **Modelo de Hiperjuego y Señalización Bayesiana:** Formalización del conflicto bajo incertidumbre, donde el atacante actualiza sus creencias a partir de señales ruidosas deliberadamente manipuladas por el defensor.
- **Simulador Open Source:** Desarrollo de una herramienta funcional [5] que materializa el modelo, garantizando reproducibilidad y ofreciendo un entorno a la comunidad.
- **Validación Experimental:** Evaluación empírica en 125 escenarios, demostrando que las estrategias proactivas alcanzan un 72 % de éxito y fuerzan al atacante a operar con utilidad negativa.

El resto de este artículo se organiza de la siguiente manera. La Sección II revisa el estado del arte en ciberengaño y la aplicación de la teoría de juegos a la seguridad informática. La Sección III formaliza analíticamente el modelo de juego propuesto y detalla su integración con la taxonomía de MITRE Engage. La Sección IV presenta el análisis exhaustivo de los resultados experimentales, discutiendo la eficacia y el impacto económico de las estrategias evaluadas. Finalmente, la Sección V resume las conclusiones principales de este estudio y plantea futuras líneas de investigación.

II. ESTADO DEL ARTE

La literatura sobre ciberengaño ha evolucionado significativamente mediante la aplicación de la Teoría de Juegos para modelar la asimetría de información. Como pilar conceptual, Cho *et al.* [6] introducen los *hiperjuegos* para formalizar escenarios donde atacante y defensor operan con percepciones topológicas divergentes. Partiendo de esta base estratégica, Schlenker *et al.* [7] proponen el *Cyber Deception Game* (CDG), enfocado específicamente en frustrar las fases de reconocimiento adversario para inducir decisiones subóptimas mediante el diseño calculado de la red expuesta.

Para gestionar matemáticamente la incertidumbre inherente a estas interacciones, Hu *et al.* [8] aplican juegos de señalización bidireccional que resuelven el equilibrio bayesiano. Este enfoque permite optimizar la selección de respuestas defensivas manipulando las creencias del atacante. Dicha manipulación se extiende a horizontes temporales más amplios en el trabajo de Wan *et al.* [9], quienes trasladan el modelo de hiperjuego a campañas de Amenazas Persistentes Avanzadas (APT) multi-etapa, demostrando cómo la alteración prolongada de la percepción degrada la eficacia operativa del intruso.

A nivel táctico y de despliegue, Anwar *et al.* [10] estructuran un hiperjuego explícito para resolver el problema de asignación de *honeypots*, evaluando el compromiso crítico entre el coste de mantenimiento y la credibilidad (sistemas de alta frente a baja interacción). Como representación de la vanguardia proactiva, Wang *et al.* [11] combinan grafos de ataque bayesianos con juegos de Stackelberg para anticipar las rutas más probables de intrusión y guiar la inyección de señuelos antes de que el ataque se materialice.

A pesar de la sofisticación analítica de estos enfoques, la mayoría comparte una limitación práctica: confinan el engaño a abstracciones matemáticas de alto nivel o a un rol puramente evasivo. En contraste, nuestra propuesta adopta una **defensa activa integral** orientada a atrapar, desgastar y perfilar al atacante. Mediante la integración del marco operativo *MITRE Engage* [3], transformamos la red en un entorno de *engagement* prolongado que invierte la asimetría tradicional, forzando al adversario a consumir recursos de forma estéril mientras el defensor extrae inteligencia procesable.

III. MODELADO FORMAL DEL JUEGO DE ENGAÑO

El modelo formaliza la dinámica adversarial bajo asimetría de información mediante un Hiperjuego de Señalización [4]. El defensor manipula estímulos técnicos para sesgar la Inferencia Bayesiana de un atacante racional, forzándole a confiar en una topología falsa. Para dotar de realismo operativo al modelo (ver Figura 1), las tácticas defensivas se mapean directamente desde el marco *MITRE Engage*.




Figura 1. Arquitectura funcional del simulador de ciberengaño.

Análíticamente, el sistema se define como un juego estocástico de suma general:

$$G = \langle N, \mathcal{E}, \mathcal{H}, \mathcal{A}, \mathcal{T}, \mathcal{U}, \Sigma, \mathcal{P} \rangle \quad (1)$$

donde $N = \{A, D\}$ son los jugadores (Atacante y Defensor); $\mathcal{E}$ el entorno; $\mathcal{H}$ las historias; $\mathcal{A}$ el espacio de acciones; $\mathcal{T}$ los tipos privados; $\mathcal{U}$ las utilidades; Σ las señales observables; y $\mathcal{P}$ las transiciones de probabilidad.

III-A. Entorno y Perfiles de Agentes

El **Entorno** ($e \in \mathcal{E}$) condiciona la matriz de incentivos y el ruido estructural del canal de comunicación:

$$\mathcal{E} = \langle \omega_{sw}, c_{sys}, \mu_{net}, \sigma_{noise}^2 \rangle \quad (2)$$

donde ω_{sw} es el atractivo del activo; c_{sys} el coste de despliegue defensivo; μ_{net} la latencia media intrínseca; y σ_{noise}^2 la varianza del ruido de fondo.

El **Atacante** se rige por un vector de perfil ($\theta_A \in \Theta_A$) que determina su comportamiento en tiempo de ejecución:

$$\Theta_A = \langle \lambda_{skill}, \rho_{risk}, \kappa_{know}, \psi_{obj} \rangle \quad (3)$$

donde $\lambda_{skill} \in [0, 1]$ atenúa los costes operativos según su habilidad; $\rho_{risk} \in [0, 1]$ es su aversión al riesgo; κ_{know} su conocimiento de tácticas de engaño; y ψ_{obj} su objetivo final. Su espacio de acciones adapta la *Cyber Kill Chain* al perímetro interno: $\mathcal{A}_A = \{\text{RECON, TEST, EXPLOIT, STEALTH, EXIT}\}$.

El **Defensor** ($\theta_D \in \Theta_D$) pondera sus objetivos operativos en base a *MITRE Engage*:

$$\Theta_D = \langle w_{eng}, w_{intel}, w_{prot}, w_{cost} \rangle \quad (4)$$

donde los coeficientes (w) normalizan la prioridad asignada a: Engaño, Inteligencia, Protección y Coste. Sus acciones $D_A = (m, s)$ (categoría táctica y mecanismo técnico) alteran las señales de red mediante una función de transformación Φ :

$$(m, s) \xrightarrow{\Phi} \{\delta(D_A), \eta(D_A), \sigma_{lat}, \sigma_{jit}\} \quad (5)$$

III-B. Señalización e Inferencia Bayesiana Contextual

El atacante no observa el estado real, sino un vector de señales ruidosas $\sigma_t = \langle \sigma_{lat}, \sigma_{jit}, \sigma_{ban}, \sigma_{tra}, \sigma_{err} \rangle$ que representan la latencia, *jitter*, *banners*, topología y errores. Estas señales se alteran estocásticamente. Por ejemplo, la latencia incorpora el sesgo (δ) y ruido (η) de la acción defensiva a_D :

$$\sigma_{lat} \sim \mathcal{N}(\mu_{net}(e) + \delta(a_D), \sigma_{noise}^2(e) + \eta(a_D)) \quad (6)$$

Con cada observación, el atacante actualiza su creencia $b_t \in [0, 1]$ (probabilidad de estar interactuando con un señuelo S en lugar de un sistema real R) usando Bayes:

$$b_{t+1} = \frac{P(\sigma_{t+1} | S, e) \cdot b_t}{P(\sigma_{t+1} | S, e)b_t + P(\sigma_{t+1} | R, e)(1 - b_t)} \quad (7)$$

Operativamente, si la señal es anómala para un sistema real en ese entorno e , la sospecha (b_{t+1}) aumenta.

III-C. Funciones de Utilidad (U)

El motor de decisión de los agentes es la maximización de su Utilidad Esperada (EU), que modela el análisis de coste-beneficio.

Utilidad del Atacante (EU_A): Contrapone la recompensa esperada frente a los riesgos de exposición y el esfuerzo:

$$EU_A = (1 - b_t)V_{asset} - \rho_{risk} [b_t C_{trap} + P(det | e) C_{det}] - \frac{C_{op}(a_A)}{\lambda_{skill}} \quad (8)$$

El V_{asset} se descuenta según su sospecha b_t ; la aversión al riesgo ρ_{risk} pondera las penalizaciones por caer en trampas (C_{trap}) o detección (C_{det}); y el coste operativo $C_{op}(a_A)$ disminuye proporcionalmente a su habilidad técnica λ_{skill} .

Utilidad del Defensor (EU_D): Maximiza la entropía generada y la inteligencia extraída, penalizando los costes operativos y las brechas de datos reales:

$$EU_D = \sum_{t=0}^T [w_{eng} \cdot H(b_t) + w_{intel} \cdot I(a_A) - w_{cost} \cdot C_{maint}(a_D, e)] - w_{prot} \cdot (\mathbb{K}_{comp} \cdot L_{data}) \quad (9)$$

donde $H(b_t)$ es la entropía de la creencia adversaria; $I(a_A)$ la inteligencia táctica recolectada; C_{maint} el coste de mantener el engaño en el entorno e ; y L_{data} una penalización crítica aplicada solo si se compromete información real ($\mathbb{K}_{comp}$).

IV. EVALUACIÓN EXPERIMENTAL Y ANÁLISIS DE RESULTADOS

La evaluación comprende 50,000 episodios de Monte Carlo sobre 125 escenarios únicos ($\Omega = \Theta_A \times \Theta_D \times \mathcal{E}$, Tabla I). Asumiendo un despliegue de señuelos (S), los resultados (Tabla II) demuestran que los atacantes apenas identifican el engaño o abortan en el 30% de los casos, garantizando al defensor una eficacia operativa superior al 70%.

IV-A. Análisis de Payoffs y Rendimientos Decrecientes

El análisis de la utilidad acumulada (EU) revela la dinámica de *suma general* del conflicto. La Figura 2 (izquierda) demuestra de forma contundente que el sistema impone un desgaste sistémico y transversal al atacante, independientemente de su sofisticación. Incluso los adversarios de perfil APT (*Very Strong*), diseñados para maximizar la evasión y minimizar riesgos, promedian una utilidad final de $-3,76$. Este rendimiento negativo sostenido se explica por el coste operativo continuo (C_{op}): al no poder distinguir inmediatamente un activo real de un señuelo, el atacante se ve forzado a ejecutar ciclos redundantes de reconocimiento (RECON) y validación (TEST). Cada acción consume su presupuesto técnico y aumenta la probabilidad acumulada de detección, drenando su utilidad antes de que pueda ejecutar la explotación.

Desde la perspectiva del defensor (Figura 2, derecha), la utilidad crece de forma proporcional a la proactividad de la




Figura 2. Distribución de utilidad por perfil de sofisticación.

estrategia hasta alcanzar un óptimo global en el perfil *Strong* (+1,99). Resulta especialmente relevante el comportamiento del perfil *Very Strong* (Cognitivo): pese a desplegar las tácticas más avanzadas de MITRE Engage, su utilidad neta decae a +1,54. Este fenómeno empírico valida la existencia de una “ley de rendimientos decrecientes” en el ciberengaño. Las infraestructuras de ultra-alta fidelidad requieren la inyección constante de tráfico sintético realista y el mantenimiento de *honeypots* de alta interacción. El enorme coste de mantenimiento (C_{maint}) de estas operaciones termina superando el beneficio marginal de la inteligencia obtenida ($I(a_A)$), demostrando que la eficiencia táctica reside en el equilibrio coste-engaño, no en el mimetismo perfecto.

IV-B. Entropía Cognitiva y Asimetría Táctica

Para desglosar la interacción estratégica, la Figura 3 presenta los mapas de calor de utilidades esperadas cruzando los distintos perfiles. Se observa que la postura defensiva *Strong* maximiza su rentabilidad frente a amenazas de nivel *Normal* (cibercrimen tradicional), ya que logra extraer suficiente inteligencia táctica de un adversario que no tiene las capacidades necesarias para identificar rápidamente las anomalías inyectadas en la red.




Figura 3. Mapas de calor de interacciones tácticas.

El mecanismo causal detrás de esta degradación adversaria es la manipulación de la incertidumbre. El análisis de los registros de simulación evidencia una fuerte correlación de Pearson negativa ($r = -0,78$) entre la Entropía de la Creencia del atacante ($H(b_t)$) y su utilidad final (EU_A). A medida que el defensor altera estocásticamente las señales (como la latencia o el *jitter*), empuja la creencia bayesiana del atacante hacia $b_t \approx 0,5$ (máxima incertidumbre). En este estado de “duda táctica”, el modelo de riesgo del atacante penaliza cualquier acción agresiva, paralizando su avance en un laberinto de señales inconsistentes.

Tabla I
PARAMETRIZACIÓN NUMÉRICA DEL ESPACIO DE SIMULACIÓN

Perfil Atacante (Θ_A)				Perfil Defensor (Θ_D)						Entorno ($\mathcal{E}$)				
Categoría	Nivel	Skill	Risk	Categoría	Nivel	w_{eng}	w_{info}	w_{prot}	w_{cost}	Categoría	Nivel	ω_{sw}	c_{sys}	Prob. Inicial
Script Kiddie	V. Weak	Low	Low	Pasiva	V. Weak	0.05	0.05	0.40	0.50	Doméstica	V. Weak	1.0	0.1	0.5
Insider	Weak	Low	Med	Estática	Weak	0.10	0.10	0.50	0.30	Oficina	Weak	3.0	0.3	0.4
Cibercrimen	Normal	Med	Med	Reactiva	Normal	0.20	0.20	0.40	0.20	Corporativa	Normal	5.0	0.5	0.5
Grupo Org.	Strong	High	High	Proactiva	Strong	0.35	0.35	0.20	0.10	Data Center	Strong	7.0	0.7	0.6
APT	V. Strong	High	High	Cognitiva	V. Strong	0.45	0.45	0.05	0.05	Infra. Crít.	V. Strong	9.0	0.9	0.7




Figura 4. Impacto de la complejidad del entorno en la utilidad defensiva.

Finalmente, esta capacidad de camuflaje está íntimamente ligada a las condiciones del campo de batalla. La Figura 4 ilustra cómo entornos complejos (como *Data Centers* o *Infraestructuras Críticas*) actúan como multiplicadores de fuerza para el defensor. En estos escenarios de nivel *Very Strong*, el elevado ruido estructural inherente a la red (σ_{noise}^2) enmascara eficazmente las anomalías artificiales introducidas por los señuelos. Esto facilita enormemente la inyección de señales falsas sin levantar sospechas adicionales.

V. CONCLUSIONES Y TRABAJO FUTURO

Este artículo presenta un simulador de código abierto [5] que integra la Teoría de Juegos con *MITRE Engage*, cerrando la brecha entre la abstracción matemática y la operatividad táctica. Los resultados demuestran que la inyección estratégica

de ruido técnico invierte la asimetría del conflicto, forzando al atacante a operar con utilidad negativa al agotar sus recursos.

El análisis económico revela que la disuasión óptima no exige infraestructuras de máxima fidelidad, sino maximizar la entropía en las creencias del adversario bajo un estricto equilibrio coste-beneficio.

Como trabajo futuro, el simulador servirá como entorno de entrenamiento en Aprendizaje por Refuerzo Profundo (DRL) para desarrollar agentes defensivos autónomos, capaces de orquestar políticas de engaño dinámicas y adaptativas en tiempo real.

AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por la Comisión Europea, a través del proyecto Horizon Europe/JU SNS ROBUST-6G (Grant Agreement n.º 101139068)

REFERENCIAS

- [1] P. Beltrán-López, M. Gil Pérez and P. Nespoli, “Cyber Deception: Taxonomy, State of the Art, Frameworks, Trends, and Open Challenges,” in *IEEE Communications Surveys & Tutorials*, vol. 28, pp. 1520–1556, 2026, doi: 10.1109/COMST.2025.3594788.
- [2] M. Zhu, A. H. Anwar, Z. Wan, J. H. Cho, C. A. Kamhoua, and M. P. Singh, “A Survey of Defensive Deception: Approaches Using Game Theory and Machine Learning,” *IEEE Communications Surveys & Tutorials*, vol. 23, no. 4, pp. 2460–2493, 2021.
- [3] MITRE Corp., “MITRE Engage: An Adversary Engagement Framework from MITRE,” 2022. [Online]. Available: <https://engage.mitre.org>
- [4] N. S. Kovach, A. S. Gibson, and G. B. Lamont, “Hypergame Theory: A Model for Conflict, Misperception, and Deception,” *Game Theory*, vol. 2015, Art. no. 570639, 2015.
- [5] CyberDataLab, “GT-Engage: Cyber Deception Simulator based on Game Theory and the MITRE Engage Framework,” 2026. [Online]. Available: <https://github.com/CyberDataLab/GT-Engage>
- [6] J.-H. Cho, M. Zhu, and M. P. Singh, “Modeling and Analysis of Deception Games Based on Hypergame Theory,” in *Proc. Autonomous Cyber Deception*, 2019, pp. 49–74.
- [7] A. Schlenker, O. Thakoor, H. Xu, F. Fang, M. Tambe, and P. Vayanos, “Game Theoretic Cyber Deception to Foil Adversarial Network Reconnaissance,” in *Adaptive Autonomous Secure Cyber Systems*, 2020, pp. 183–204.
- [8] Y. Hu, H. Zhang, Y. Guo, T. Li, and J. Ma, “A Novel Attack-and-Defense Signaling Game for Optimal Deceptive Defense Strategy Choice,” in *Wireless Communications and Mobile Computing*, vol. 2020, 2020.
- [9] Z. Wan, J.-H. Cho, M. Zhu, A. H. Anwar, C. A. Kamhoua, and M. P. Singh, “Foureye: Defensive Deception Against Advanced Persistent Threats via Hypergame Theory,” *IEEE Transactions on Network and Service Management*, vol. 19, no. 1, pp. 112–129, 2021.
- [10] A. H. Anwar, M. Zhu, Z. Wan, J.-H. Cho, C. A. Kamhoua, and M. P. Singh, “Honey-pot-Based Cyber Deception Against Malicious Reconnaissance via Hypergame Theory,” in *Proc. IEEE GLOBECOM*, 2022, pp. 3393–3398.
- [11] R. Wang, C. Yang, X. Deng, Y. Zhou, Y. Liu, and Z. Tian, “Turn the Tables: Proactive Deception Defense Decision-Making Based on Bayesian Attack Graphs and Stackelberg Games,” *Neurocomputing*, vol. 638, 2025.

Tabla II
RESUMEN CUANTITATIVO DE DESEMPEÑO POR PERFIL DE AGENTE

Perfil del Agente	Utilidad Media (μ)	Dev. Est. (σ)	Creencia (b_t)	Éxito (E) ¹ (%)
<i>Perspectiva del Atacante (U_A)</i>				
Very Weak (Script Kiddie)	-12.73	± 4.51	0.494	36.0 %
Weak (Insider)	-10.71	± 2.88	0.452	28.0 %
Normal (Cibercrimen)	-6.98	± 1.63	0.472	32.0 %
Strong (Grupo Org.)	-5.56	± 3.18	0.490	32.0 %
Very Strong (APT)	-3.76	± 3.26	0.479	24.0 %
<i>Perspectiva del Defensor (U_D)</i>				
Very Weak (Pasivo)	+0.77	± 3.10	-	60.0 %
Weak (Estático)	+0.82	± 2.70	-	60.0 %
Normal (Reactivo)	+1.35	± 2.82	-	64.0 %
Strong (Proactivo)	+1.99	± 2.79	-	72.0 %
Very Strong (Cognitivo)	+1.54	± 2.14	-	68.0 %

¹Para el atacante, éxito de inferencia táctica; para el defensor, tasa de protección.

Encrypted but Not Private: Application Identification from Traffic Metadata at Scale

Farzam Rezaei, Jorge E. López de Vergara, Luis de Pedro and Iván González

Escuela Politécnica Superior, Universidad Autónoma de Madrid, Spain

{farzam.rezaei, jorge.lopez_vergara, luis.depedro, ivan.gonzalez}@uam.es

Abstract—It is well established that TLS and QUIC protect payload confidentiality but leave packet-level metadata exposed, enabling traffic analysis. However, the practical extent to which application identities can be inferred at backbone scale using only such metadata remains less thoroughly quantified. In this paper, we present a large-scale empirical study of application identification on the CESNET-TLS-Year22 dataset (10.7M flows) under a strict metadata-only setting, relying on packet sizes, inter-packet times, directions, and early packet sequences (PPI), with and without TCP PSH flags. We systematically compare tree-based models (Random Forest, LightGBM, XGBoost) and a GPU-accelerated MLP, evaluating both classification accuracy and inference throughput. Our results confirm and quantify the limited application-level privacy provided by encryption: a PPI-based MLP achieves 95–96% accuracy (macro F1 > 0.94) across hundreds of services while processing millions of flows per second. TCP PSH flags consistently improve performance, whereas combining histogram and sequence features yields marginal gains.

Index Terms—Encrypted traffic classification, TLS privacy, traffic fingerprinting, CESNET-TLS-Year22, PHIST histograms, PPI packet sequences, TCP PSH flags, GPU MLP, application identification, large-scale benchmark.

I. INTRODUCTION

The increasing adoption of TLS and QUIC has reduced network visibility by preventing payload inspection, challenging traffic engineering, monitoring, and security enforcement [1], [2]. While encryption protects payload content, it is well known that packet-level metadata remains exposed, enabling traffic analysis [3], [4]. However, the practical extent to which backbone traffic can be fingerprinted at scale—using only metadata and without handshake identifiers—remains less comprehensively benchmarked. Existing studies typically focus on individual methods or feature sets without systematic comparison under unified conditions [5]–[8].

In this paper, we present a large-scale empirical evaluation of application identification on CESNET-TLS-Year22 [7], systematically comparing histogram-based features and early packet sequences (PPI, with and without TCP PSH flags) across tree-based models and a GPU-accelerated MLP. Our results confirm that application identification remains highly accurate (95–96%) using only packet dynamics, quantifying the limited application-level privacy provided by current encryption. Inference throughput is reported as a measure of deployment feasibility, assessing whether such identification is practical in real-time settings. We emphasize that our contribution is primarily empirical, and that identifying ap-

plications from traffic metadata does not by itself constitute a privacy violation without linking connections to specific user identities.

The paper provides the following contributions: (i) a systematic evaluation of histogram and PPI features (including PSH flags) on a large-scale dataset, (ii) a comparison of classical and neural models under a unified setup, and (iii) a discussion of the scope and limitations of metadata-based identification with respect to application-level privacy. To the best of our knowledge, no prior work evaluates these matters at this scale.

The rest of the paper is structured as follows: Section II reviews related work. Section III describes the methodology. Section IV presents experimental results. Section V discusses privacy implications. Finally, Section VI concludes the paper.

II. RELATED WORK

Network traffic classification has evolved from payload-based inspection to metadata-driven approaches due to the widespread adoption of encryption. Early techniques such as port-based identification and DPI are now ineffective or impractical in TLS-dominated environments, motivating the shift toward flow-based methods that rely on observable traffic characteristics (e.g., packet sizes, timing, direction) [5], [6], [9].

Apart from these common features, NEMEA [10] traffic analysis tool also provides two feature families. Histogram-based features (PHIST) summarize packet sizes and inter-packet times into compact distributions, offering efficiency and robustness [8]. Packet Payload Information (PPI) captures the sequence of early packets in a flow, encoding temporal behavior and improving discriminative power, sometimes augmented with TCP flags [8], [11]. These representations are widely supported in CESNET datasets [12], which have become standard benchmarks for realistic evaluation.

A variety of machine learning models have been applied to these features. Tree-based methods such as Random Forest and gradient boosting (e.g., LightGBM) remain strong baselines for tabular data, while neural models (CNNs, RNNs, MLPs) can better exploit sequential patterns but introduce higher computational cost [13]–[15].

Despite avoiding payload inspection, metadata-based classification raises privacy concerns. It is well established that encryption does not hide traffic metadata, enabling the inference of visited websites or user activities from traffic patterns alone [3], [4], [16]. Our work builds on this understanding




Fig. 1. Overview of the proposed methodology on CESNET-TLS: preprocessing → feature construction (PHIST, PPI, combined) → model training (RF/LightGBM/XGBoost/MLP) → prediction and evaluation.

by providing a systematic, large-scale benchmark comparing PHIST and PPI features across classical and neural models on CESNET-TLS-Year22, quantifying the extent of application-level information leakage under a strict metadata-only setting.

III. METHODOLOGY

We evaluate application identification from encrypted traffic using CESNET-TLS-Year22 under a strict metadata-only setting (packet sizes, timings, directions, and TCP flags). The task is multi-class classification of services (180 classes) using temporally separated train/test splits to reflect realistic deployment, as shown in Figure 1.

A. Features

We consider two standard feature families available in CESNET-TLS: (i) histogram features (PHIST, 32D), which summarize packet sizes and inter-packet times per direction, and (ii) packet sequences (PPI), encoding up to the first $K = 30$ packets using sizes, directions, inter-packet times, and optionally TCP PSH flags (90D without PSH, 120D with PSH). We also evaluate their concatenation (152D) to test complementarity.

B. Preprocessing

Flows are parsed from CSV files, features are constructed (PHIST, PPI, or combined), and labels are encoded from training data. Histograms are L1-normalized; all features are standardized for classical models. No class rebalancing is applied to preserve realistic distributions. Preprocessed datasets are cached to enable reproducible large-scale experiments.

C. Models

We compare tree-based ensembles (Random Forest, LightGBM, XGBoost) and a GPU-based MLP. Tree models are tuned with lightweight search over depth and number of estimators. The MLP consists of two hidden layers with ReLU, dropout, and AdamW optimization; hyperparameters are selected using validation-based tuning. The final model is exported for efficient batch inference.

Model Performance Comparison




Fig. 2. Overall model performance comparison on CESNET-TLS-Year22 in terms of Accuracy, weighted F1-score, and macro F1-score (higher is better). Numbers in parentheses show the dimension of the input and the number of flows in the training.

D. Evaluation

Performance is measured using accuracy and macro F1-score, aggregated across temporally separated test splits. We also report inference throughput (flows/s) to assess deployment feasibility. Experiments are executed on a multi-GPU server to enable large-scale evaluation.

Inference throughput is not merely a systems metric: it directly determines whether metadata-based application identification constitutes a *practical* privacy concern. A classifier that is accurate but very slow for real-time use poses only a theoretical risk; one that processes millions of flows per second can be deployed transparently at backbone scale, making the privacy threat concrete and immediate.

IV. RESULTS

We report accuracy, macro F1, and inference throughput on CESNET-TLS-Year22 under a metadata-only setting. The key questions are: (i) which feature representation is most effective, and (ii) whether models scale to backbone traffic.

A. Main Results

Table I summarizes the best configurations. PPI-based MLPs clearly outperform histogram-only approaches, reaching 95–96% accuracy and macro F1 above 0.93 across hundreds of classes. The best trade-off is achieved by PPI+PSH (120D), which combines high accuracy (~95.7%) with very high throughput (~7M flows/s).

Histogram-only models remain competitive but clearly weaker (~90% accuracy). Among them, LightGBM is the strongest baseline (~93%), while XGBoost and Random Forest perform significantly worse (~78%). Figure 2 visualizes the overall accuracy, weighted F1, and macro F1 across the evaluated models.

TABLE I
OVERALL PERFORMANCE AND EFFICIENCY OF THE EVALUATED MODELS ON CESNET-TLS-YEAR22.

Model	Features (dim)	Flows (train / test)	Accuracy	F1 (weighted)	F1 (macro)	Flows/s	Inference time
MLP (2-hidden-layer)	Hist + PPI + PSH (152D)	1 Week / 1 Week	0.9514	0.9510	0.9284	3.30M	3.24 s
MLP (2-hidden-layer)	PPI + PSH (120D)	1 Year (Sampled) / 1 Week	0.9575	0.9573	0.9412	7.09M	1.51 s
MLP (2-hidden-layer)	PPI only (90D); no PSH	1 Year (Sampled) / 1 Week	0.9557	0.9556	0.9388	4.40M	2.43 s
MLP (2-hidden-layer)	PPI + PSH (120D)	1 Week / 1 Week	0.9494	0.9490	0.9271	6.60M	1.62 s
MLP (2-hidden-layer)	PPI only (90D); no PSH	1 Week / 1 Week	0.9507	0.9504	0.9265	5.52M	1.94 s
MLP (2-hidden-layer)	Hist only (32D)	1 Week / 1 Week	0.8971	0.8964	0.8615	1.19M	9.02 s
LightGBM	Hist (32D)	1 Year (Sampled) / 1 Week	0.9333	0.9421	0.9256	0.08M	14.4 s
XGBoost	Hist (32D)	1 Year (Sampled) / 1 Week	0.7872	0.7846	0.7593	≈0.07M	10.76 s
Random Forest	Hist (32D)	1 Year (Sampled) / 1 Week	0.7805	0.7674	0.7481	≈0.005M	20.35 s




Fig. 3. Per-class F1-score heatmap for the 30 most challenging application classes, comparing representative PPI-based MLP variants. Rows are selected by lowest per-class F1 under the PPI-only (90D, no PSH, 10M) model.

B. Impact of Features

Moving from histograms to packet sequences provides the largest performance gain ($\sim +6\%$ accuracy). Adding TCP PSH flags yields a smaller but consistent improvement ($\sim +0.2\%$). In contrast, combining histograms with PPI provides only marginal benefits, suggesting that early packet dynamics already capture most discriminative information. Figure 3 reports per-class F1-scores for the most challenging classes across representative PPI-based models.

C. Scalability

All MLP models are executed on GPU using TorchScript. The best configuration (PPI+PSH) processes more than 7 M flows/s, enabling real-time backbone deployment. In contrast, tree-based models on CPU remain two orders of magnitude slower ($\sim 70\text{--}80\text{k}$ flows/s).

The experiments were run on a high-performance server with two AMD EPYC 7F72 CPUs (24 cores/48 threads each at 3.2 GHz), 1 TB DDR4 RAM, and four NVIDIA A100-SXM4 GPUs (40 GB HBM2 each); throughput values correspond to single-GPU inference with large batches.

Overall, results show that encrypted traffic still leaks sufficient information for accurate application identification, and

that this identification is feasible in real time, strengthening the practical relevance of the observed privacy–visibility trade-off.

V. DISCUSSION

Encryption ensures payload confidentiality but does not prevent application-level fingerprinting from traffic metadata. Using only flow-level features, our best MLP (PPI+PSH) achieves $\sim 95.7\%$ accuracy (macro F1 ~ 0.94) across hundreds of classes at multi-million flows/s. These results empirically confirm and quantify a well-known limitation of transport-layer encryption: while payload content is protected, packet sizes, timings, directions, and TCP flags remain highly discriminative [3], [4].

It is important to note, however, that identifying application names or service categories from flow metadata does not, by itself, constitute a direct violation of user privacy. A critical additional step—linking identified connections to specific user identities—would be required for such identification to translate into meaningful privacy harm. Our results therefore characterize the information leakage from encrypted metadata rather than demonstrate a complete privacy attack.

From a practical standpoint, inference throughput is relevant because it determines whether metadata-based identification can be deployed at backbone scale in real time. GPU-based MLPs are both more accurate and orders of magnitude faster than CPU tree ensembles, making such deployment feasible. This has implications both for network operators seeking visibility and for privacy researchers evaluating the real-world threat of traffic analysis. Figure 4 highlights the corresponding relationship of inference speed and macro F1.

Notably, approaches that remove handshake identifiers (e.g., ECH) are unlikely to prevent such inference, as our models rely purely on traffic dynamics. Future defenses such as TLS-level padding [17] or traffic shaping should be evaluated against the baselines established here.

VI. CONCLUSIONS

We presented a large-scale empirical evaluation of metadata-only application identification on CESNET-TLS-Year22, systematically comparing histogram features and early packet sequences (PPI, with/without TCP PSH) across tree-based models and a GPU-accelerated MLP. PPI+PSH with MLP provides the best trade-off, achieving $\sim 95\text{--}96\%$ accuracy with multi-million flows/s throughput.




Fig. 4. Inference speed (flows/s, log scale) vs. Macro-F1 across evaluated models, illustrating scalability under high traffic volumes.

Our results confirm and quantify the known limitation that encryption protects payloads but not application identities: early encrypted traffic dynamics suffice for accurate service fingerprinting at backbone scale. While this does not constitute a direct privacy violation—as linking connections to individual users requires additional steps—it highlights a measurable information leakage that merits attention from the privacy community.

Future work should assess the importance of K in the PPI, cross-dataset generalization, robustness to protocol-level defenses (e.g., TLS padding), and lightweight interpretability to understand which features drive predictions. Code and implementation details are publicly available at: GitHub¹.

ACKNOWLEDGEMENTS

This work is partially funded by a grant from the Dept. of Electronics and Communication Technologies at Universidad Autónoma de Madrid, as well as by an R&D activity program with reference TEC-2024/COM-504 and acronym RAMONES-CM, granted by the Comunidad de Madrid, Spain, through the Directorate General for Research and Technological Innovation via Order 5696/2024.

REFERENCES

- [1] M. Shen, K. Ye, X. Liu, L. Zhu, J. Kang, S. Yu, Q. Li, and K. Xu, "Machine learning-powered encrypted network traffic analysis: A comprehensive survey," *IEEE Communications Surveys & Tutorials*, vol. 24, no. 1, pp. 409–454, 2022.
- [2] I. A. Alwhbi, C. C. Zou, and R. N. Alharbi, "Encrypted network traffic analysis and classification utilizing machine learning," *Sensors*, vol. 24, no. 11, p. 3509, 2024.
- [3] A. Panchenko, F. Lanze, J. Pennekamp, T. Engel, A. Zinnen, M. Henze, and K. Wehrle, "Website fingerprinting at internet scale," in *Proceedings of the 2016 Network and Distributed System Security Symposium (NDSS)*, 2016.
- [4] K. P. Dyer, S. E. Coull, T. Ristenpart, and T. Shrimpton, "Peek-a-boo, i still see you: Why efficient traffic analysis countermeasures fail," in *2012 IEEE symposium on security and privacy*. IEEE, 2012, pp. 332–346.
- [5] A. W. Moore and D. Zuev, "Internet traffic classification using Bayesian analysis techniques," in *Proceedings of the 2005 ACM SIGMETRICS International Conference on Measurement and Modeling of Computer Systems*. ACM, 2005, pp. 50–60.
- [6] P. Velan, M. Čermák, P. Čelada, and M. Drašar, "A survey of methods for encrypted traffic classification and analysis," *International Journal of Network Management*, vol. 25, no. 5, pp. 355–374, 2015.
- [7] K. Hynek, J. Luxemburk, J. Pešek, T. Čejka, and P. Šiška, "CESNET-TLS-Year22: A year-spanning tls network traffic dataset from backbone lines," *Scientific Data*, vol. 11, p. 1156, 2024.
- [8] J. Luxemburk and T. Čejka, "Fine-grained TLS services classification with reject option," *Computer Networks*, vol. 220, p. 109467, 2023.
- [9] N. Williams, S. Zander, and G. Armitage, "A preliminary performance comparison of five machine learning algorithms for practical ip traffic flow classification," *SIGCOMM Comput. Commun. Rev.*, vol. 36, no. 5, p. 5–16, Oct. 2006. [Online]. Available: <https://doi.org/10.1145/1163593.1163596>
- [10] T. Čejka, V. Bartos, M. Svejpes, Z. Rosa, and H. Kubatova, "Nemear: A framework for network traffic analysis," in *12th International Conference on Network and Service Management (CNSM 2016)*, 2016. [Online]. Available: <http://dx.doi.org/10.1109/CNSM.2016.7818417>
- [11] M. Shen, K. Ye, X. Liu, L. Zhu, J. Kang, S. Yu, Q. Li, and K. Xu, "Machine learning-powered encrypted network traffic analysis: A comprehensive survey," *IEEE Communications Surveys & Tutorials*, vol. 25, no. 1, pp. 791–824, 2023.
- [12] J. Luxemburk and K. Hynek, "Datazoo: Streamlining traffic classification experiments," in *Proceedings of the 2023 Workshop on Explainable and Safety Bounded, Fidelity, Machine Learning for Networking (SAFE '23)*. New York, NY, USA: ACM, 2023, pp. 3–7.
- [13] L. Breiman, "Random forests," *Mach. Learn.*, vol. 45, no. 1, p. 5–32, Oct. 2001. [Online]. Available: <https://doi.org/10.1023/A:1010933404324>
- [14] G. Ke, Q. Meng, T. Finley, T. Wang, W. Chen, W. Ma, Q. Ye, and T.-Y. Liu, "LightGBM: A highly efficient gradient boosting decision tree," in *Proceedings of the 31st International Conference on Neural Information Processing Systems (NeurIPS 2017)*, 2017, pp. 3149–3157.
- [15] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. MIT Press, 2016.
- [16] E. Papadogiannaki and S. Ioannidis, "A survey on encrypted network traffic analysis applications, techniques, and countermeasures," *ACM Comput. Surv.*, vol. 54, no. 6, Jul. 2021. [Online]. Available: <https://doi.org/10.1145/3457904>
- [17] E. Rescorla, "The Transport Layer Security (TLS) Protocol Version 1.3," RFC 8446, Aug. 2018. [Online]. Available: <https://www.rfc-editor.org/info/rfc8446>

¹<https://github.com/farzamrezaei/Traffic-Classification-of-CESNET-TLS-Year22>

Verifiable Batch Evaluation of Nonlinear Functions with High Precision for Machine Learning

Martí Batista i Obiols
Universitat Pompeu Fabra
Barcelona, Spain
marti.batista@upf.edu

Antonio Peso
Universitat Pompeu Fabra
Barcelona, Spain
antonio.peso@upf.edu

Carla Ràfols
Universitat Pompeu Fabra
Barcelona, Spain
carla.rafols@upf.edu

Vanesa Daza
Universitat Pompeu Fabra
Barcelona, Spain
vanesa.daza@upf.edu

Abstract—Outsourcing machine learning to third parties creates a trust gap where providers may use computational shortcuts or inaccurate models. While Verifiable ML ensures integrity via cryptographic proofs, certifying the non-linear components of modern models remains a prohibitive performance bottleneck. To address this, we introduce a high-precision, batched certification scheme by leveraging an approximate sum-check protocol to drastically reduce proof overhead. We further propose a degree-reduction method that enables a few low-degree checks to certify large batches of non-linear evaluations simultaneously.

Index Terms—Verifiable machine learning, non-linear function verification, approximate sum-check, batch verification

Tipo de contribución: Investigación en desarrollo

I. INTRODUCTION

Machine Learning (ML) models are being increasingly used to perform predictions to support decisions that are critical in terms of security and safety. In most deployments, inference of these ML models is offered as a service: a client submits an input x to a remote provider and receives a prediction $y = F(x)$. Verifiable ML (VML) addresses this gap by attaching cryptographic evidence to the executed computations, allowing a prover (the service provider) to produce a proof that convinces a verifier (the client, auditor or automated policy engine) of the integrity of the claimed output.

In the specific case of Neural Network models, inference is formed by essentially 2 types of operations: linear operations (such as matrix products or convolutions) and nonlinear ones (such as element-wise activations, normalization primitives or pooling operations). Providing cryptographic integrity of nonlinear operations is far more demanding than doing so for linear ones. The reason behind this difficulty is the arithmetic mismatch between the deployed inference (which is approximate by design and operates with floating point numbers) and the current verification methods (which often operate over finite fields and rely on exact algebraic checks). This fundamental mismatch makes the nonlinear operations become the main performance bottleneck. In this paper, we address this problem by proposing a novel high-precision, batched verification scheme that allows a prover to certify the correct evaluation of non-linear functions to a verifier.

Problem Description: Currently, it is not straightforward to prove that some given tuples $(x_1, y_1), \dots, (x_L, y_L) \in \mathbb{R}^2$ satisfy that $y_i = f(x_i)$, for all $i \in \{1, \dots, L\}$, where f is a general real function. In contrast, it is much easier to prove statements of this kind when restricting ourselves to polynomial functions. Consider $p(X) \in \mathbb{R}[X]$ a polynomial of degree d_p that approximates a non-linear function $f : I \subseteq$

$\mathbb{R} \rightarrow \mathbb{R}$ on the interval I . The prover will seek to convince the verifier that the tuples $(x_1, y_1), \dots, (x_L, y_L) \in \mathbb{R}^2$ satisfy that $(p(x_i) - y_i)^2 < \delta_1$ for all $i \in \{1, \dots, L\}$, where δ_1 represents a small error tolerance. Crucially, if the verifier is convinced, the values used in later stages of inference or training on the model will be the y_i terms, which correspond to the high-precision evaluations of f . If the prover has not been honest, it can be guaranteed that the y_i cannot differ enormously from the correct value. In the context of VML, this challenge is fundamental for validating the evaluation of activation functions during the inference and training stages. Given that current models work with a large number of inputs, the number of evaluations L is high. Consequently, to avoid the verifier cost being linear in L , it is crucial that correct evaluation tests are efficiently groupable.

II. PRELIMINARIES

A. Polynomial IOPs for $\mathbb{R}$

We recall the definition of Polynomial Interactive Oracle Proofs (PIOPs) for the real numbers, following [2].

Definition 1. In our setting we define a PIOP as an interactive proof [3] in which a prover $\mathcal{P}$ can send a polynomial oracle $[p]$ to a verifier $\mathcal{V}$ for a polynomial $p \in \mathbb{R}[X_1, \dots, X_L]$. From such a polynomial oracle, the verifier can then query some evaluations. Namely, for any $\vec{s} \in \mathbb{R}^l$, a query $\vec{s}$ to the oracle provides the verifier with the polynomial evaluation $p(\vec{s})$.

Remark 1. In order to use PIOPs in a practical setting, one needs a Polynomial Commitment Scheme (PCS) (see [4]), which is a cryptographic primitive that allows a prover $\mathcal{P}$ to commit to a polynomial p in such a way that he can later convince a verifier $\mathcal{V}$ that $p(u) = v$ for some requested evaluation point u . A PIOP can be compiled with a PCS to obtain a public coin interactive argument of knowledge by replacing every oracle sent by the prover with a commitment to the corresponding polynomial and by replacing every verifier query to an oracle $[p]$ at a point $\vec{s}$ with the respective verifiable evaluation provided by the PCS. In this work we will present a PIOP that allows a prover $\mathcal{P}$ to convince a verifier $\mathcal{V}$ of the correct evaluation of a nonlinear function in several points, but a full practical protocol will remain as object of future work. The reason is that, as pointed out in [1], a PCS for real polynomials does not (yet) exist.

B. The sumcheck protocol for approximate computations

In our proposal we will use the results presented in the recent work of Bitan et al. [1], where the traditional sumcheck

protocol is generalized to extend it to any integral domain equipped with a metric that satisfies some basic properties. We are interested in $\mathbb{R}$, with the traditional euclidean distance $D(x, y) := |x - y|$. Denote by ε the absolute error given by the implementation of the arithmetic operations in this integral domain; i.e. if $\oplus, \ominus, \otimes$ are the implementations of the addition, subtraction and multiplication (respectively), then it holds that for every $u, v \in \mathbb{R}$, $D(u \oplus v, u + v), D(u \ominus v, u - v), D(u \otimes v, u \times v) \leq \varepsilon$. The protocol in 1 has been slightly modified with respect to the original to state it as a PIOP, since it will be convenient for later sections.

Theorem 1. *Let g be a v variate real polynomial, of individual degree $\leq d$. Given parameters $\delta, \Delta \in \mathbb{R}$ (with $\delta < \Delta$), a finite set $S \subseteq \mathbb{R}$ and a claimed approximate summation result $H \in \mathbb{R}$, the protocol described in Fig. 1 holds the following properties:*

- **Completeness:** *If it holds that $\delta \geq d \cdot 2^v \cdot \varepsilon$ and that $D\left(H, \sum_{(b_1, \dots, b_v) \in \{0,1\}^v} g(b_1, \dots, b_v)\right) \leq \delta$.*
- **Soundness:** *If $D\left(H, \sum_{(b_1, \dots, b_v) \in \{0,1\}^v} g(b_1, \dots, b_v)\right) > \Delta$, the verifier will just accept with probability $\leq \frac{v\delta}{|S|} + 2^v \cdot c_d \sqrt{\frac{v\delta}{\Delta}}$, where $c_d \approx 3d$ (see the original paper for an explicit determination).*

III. OUR PROTOCOL PROPOSAL

High-level overview: We reformulate the verification of nonlinear functions as a summation problem over the Boolean hypercube, utilizing an amplification function to clearly distinguish between correct evaluations and incorrect ones. To ensure this procedure is sound, we introduce a degree-reduction technique that decomposes what would otherwise be a prohibitively complex high-degree polynomial into a chain of manageable, low-degree *reduction polynomials*.

Let $l = \log L$ and $e, g : \{0,1\}^l \rightarrow \mathbb{R}$ be functions that canonically map the inputs x_i and y_i , respectively, for $i \in \{1, \dots, L\}$. Consider $E, G : \mathbb{R}^l \rightarrow \mathbb{R}$ the respective multilinear extensions. Then, what the prover wants to prove is that for some small $\delta_1 \in \mathbb{R}$, the following condition holds:

$$[(p \circ E)(\vec{z}) - G(\vec{z})]^2 < \delta_1, \forall \vec{z} \in \{0,1\}^l \quad (7)$$

A first naïve approach could be to directly perform a sumcheck protocol as the one described in 1 with the polynomial $[(p \circ E)(\vec{X}) - G(\vec{X})]^2$ over $\{0,1\}^l$, with $H = 0$, $\delta = L \cdot \delta_1$ and a corresponding Δ big enough to provide a valid soundness error bound. The limitations of this approach in terms of error tolerance make it impractical, so an alternative that provides better bounds is required. Motivated by the function x^a and its behaviour near to 1 (for a big enough), we consider constants $\delta_2, \delta_3 \in \mathbb{R}$ s.t. $\delta_1 < \delta_2 < \delta_3$ and the function $f(x) := (\frac{x}{\delta_2})^a$. Our goal is to pick δ, Δ s.t. if all of the evaluations are $< \delta_1$, then the entire summation is smaller than δ , and if just one of them is bigger than δ_3 , then the summation is bigger than Δ . Observe how, for increasing values of a , f maps terms $x < \delta_1$ close to 0 and terms $x > \delta_3$ to very high values. Furthermore, note how the higher a is, the closer $\delta_1, \delta_2, \delta_3$ can be to each other while maintaining the same effect. Then, it is natural to reformulate the polynomial that we are using for the approximate sumcheck as follows:

$$g(\vec{X}) := \left(\frac{[(p \circ E)(\vec{X}) - G(\vec{X})]^2}{\delta_2} \right)^a \quad (8)$$

Following this reasoning, we define $\delta := L \cdot (\frac{\delta_1}{\delta_2})^a$ and $\Delta := (\frac{\delta_3}{\delta_2})^a$, which offer considerably better error tolerance bounds. However, while this is the fundamental idea of the protocol that will be presented in following sections, attempting to apply it directly with this strategy would be impractical. Unlike the traditional sumcheck protocol (targeted for finite fields), the protocol described in 1 cannot really handle polynomials of individual degree that is not **very** small. Then, our goal in this work will consist on somehow *reducing* this degree to a practical range.

A. A first result

In this section we will make a first construction, used in later stages, which might be of independent interest.

Definition 2 (Reduction Polynomials). *Let $F \in \mathbb{R}[X_1, \dots, X_l]$ be a multilinear polynomial. Let $q_1, \dots, q_k \in \mathbb{R}[X]$ be degree-2 univariate polynomials, and let $p = q_1 \circ \dots \circ q_k \circ F$. We define as (multilinear) *reduction polynomials* the following, where $\chi_{\vec{z}}$ is the multilinear extension of the function $\{0,1\}^l \rightarrow \mathbb{R}$ that maps $\vec{z}$ to 1 and the remaining vertices to 0:*

$$\begin{aligned} r_{k+1}(\vec{X}) &:= F(\vec{X}) \\ r_k(\vec{X}) &:= \sum_{\vec{z} \in \{0,1\}^l} (q_k \circ r_{k+1})(\vec{z}) \chi_{\vec{z}}(\vec{X}) \\ &\vdots \\ r_1(\vec{X}) &:= \sum_{\vec{z} \in \{0,1\}^l} (q_1 \circ r_2)(\vec{z}) \chi_{\vec{z}}(\vec{X}) \end{aligned} \quad (9)$$

As a high level description, assume now that a prover $\mathcal{P}$ and a verifier $\mathcal{V}$ want to engage in a sumcheck protocol for the approximate computation $\sum_{\vec{z} \in \{0,1\}^l} p(\vec{z}) \approx 0$, where the polynomial p is as in Def. 2, and $q_1, \dots, q_k$ are public. Note how, if k is not tiny, the degree of this polynomial p will be excessively large, as in the previous case. In order to overcome this limitation, the prover will construct all of these reduction polynomials, and will send oracles $[r_1], \dots, [r_{k+1}]$ to the verifier. Note how $\sum_{\vec{z} \in \{0,1\}^l} p(\vec{z}) = \sum_{\vec{z} \in \{0,1\}^l} r_1(\vec{z})$, and therefore, as the degree of r_1 is just 1, the sumcheck $\sum_{\vec{z} \in \{0,1\}^l} r_1(\vec{z}) \approx 0$ can be performed. Of course, performing this verification is not enough, since there is no guarantee that r_1 has been computed following the structure in Def. 2. With the goal of obtaining such guarantees, observe how validating the integrity of r_1 can be reduced to the validation of r_2 by checking that $\sum_{\vec{z} \in \{0,1\}^l} (r_1(\vec{z}) - (q_1 \circ r_2)(\vec{z}))^2 \approx 0$.

We can now validate the integrity of r_2 by performing an analogous check, which will reduce the problem to the verification of the integrity of r_3 . We can proceed inductively until we reach the polynomial F , and then we are done. Therefore, the original problem of a sumcheck for a polynomial of degree 2^k has been reduced to k sumchecks of polynomials of degree 4, which can be performed directly. This procedure is precisely stated in Fig. 2.

Remark 2. This protocol can be extended to the case in which F is of the shape $\sum_{i=1}^m q_1^i \circ \dots \circ q_{k_i}^i \circ F_i$, where

Setup. The prover holds a v -variate polynomial g over $\mathbb{R}$ of degree at most d in each variable, and sends an oracle $[g]$ to the verifier. Moreover, the prover and the verifier agree on a finite set S and parameters δ and Δ . If any of the verifier's checks fail during the protocol, she immediately rejects.

Round 1. The prover computes the sum-check value $H \in \mathbb{R}$ with error at most δ . It sends the verifier H with the claim:

$$D\left(H, \sum_{(b_1, \dots, b_v) \in \{0,1\}^v} g(b_1, \dots, b_v)\right) \leq \Delta \quad (1)$$

and a polynomial $p_1(x) \in \mathbb{R}_d[x]$ claimed to approximately equal $\sum_{(b_2, \dots, b_v) \in \{0,1\}^{v-1}} g(x, b_2, \dots, b_v)$. The verifier checks that $p_1(x)$ is a univariate polynomial of degree $\leq d$ and that

$$D\left(H, \sum_{b_1 \in \{0,1\}} p_1(b_1)\right) \leq \delta, \quad (2)$$

and subsequently sends a random challenge $r_1 \sim U(S)$ to the prover.

Round $k \in \{2, \dots, v-1\}$. The prover sends the verifier a polynomial $p_k(x) \in \mathbb{R}_d[x]$ claimed to approximately equal

$$\sum_{(b_{k+1}, \dots, b_v) \in \{0,1\}^{v-k}} g(r_1, \dots, r_{k-1}, x, b_{k+1}, \dots, b_v). \quad (3)$$

The verifier checks that $p_k(x)$ is a univariate polynomial of degree $\leq d$ and that

$$D\left(p_{k-1}(r_{k-1}), \sum_{b_k \in \{0,1\}} p_k(b_k)\right) \leq \frac{\delta}{2^{k-1}}, \quad (4)$$

and subsequently sends a random challenge $r_k \sim U(S)$ to the prover.

Round v . The prover sends the verifier a polynomial $p_v(x) \in \mathbb{R}_d[x]$ claimed to approximately equal $g(r_1, \dots, r_{v-1}, x)$. The verifier checks that $p_v(x)$ is a univariate polynomial of degree $\leq d$ and that

$$D\left(p_{v-1}(r_{v-1}), \sum_{b_v \in \{0,1\}} p_v(b_v)\right) \leq \frac{\delta}{2^{v-1}}, \quad (5)$$

and draws a random challenge $r_v \sim U(S)$ to check that

$$D(p_v(r_v), g(r_1, \dots, r_v)) \leq \frac{\delta}{2^v} \quad (6)$$

For this final check, the verifier obtains the value $g(r_1, \dots, r_v)$ by querying the oracle. If this final check passes, the verifier accepts the prover's claim.

Fig. 1: The approximate sum-check protocol over $\mathbb{R}$ with the euclidean metric.

$F_i(X_1, \dots, X_l) \in \mathbb{R}^l$ is multilinear and $q_1^i, \dots, q_{k_i}^i$ are degree 2 univariate polynomials. To do so, besides the reduction polynomials defined in Def. 2, the prover will have to compute the following ones too, and send in Step 0 the corresponding oracles to the verifier, for every $i \in \{1, \dots, m\}$:

$$\begin{aligned} r_{k_i+1}^i(\vec{X}) &:= F_i(\vec{X}) \\ r_{k_i}^i(\vec{X}) &:= \sum_{\vec{z} \in \{0,1\}^l} (q_{k_i}^i \circ r_{k_i+1}^i)(\vec{z}) \chi_{\vec{z}}(\vec{X}) \\ &\vdots \\ r_1^i(\vec{X}) &:= \sum_{\vec{z} \in \{0,1\}^l} (q_1^i \circ r_2^i)(\vec{z}) \chi_{\vec{z}}(\vec{X}) \end{aligned} \quad (10)$$

Once Step 0 is completed, Steps 1 to $k+1$ will be the same as described in 2, but now the interaction will not stop

here; instead, it will be checked (with constants δ and Δ) that $\sum_{\vec{z} \in \{0,1\}^l} (r_{k+1}(\vec{z}) - \sum_{i=1}^m r_1^i(\vec{z}))^2 \approx 0$. After this check, the following ones will follow, again with sumcheck constants δ and Δ , for $i \in \{1, \dots, m\}$:

$$\begin{aligned} &\sum_{\vec{z} \in \{0,1\}^l} (r_1^i(\vec{z}) - (q_1^i \circ r_2^i)(\vec{z}))^2 \approx 0 \\ &\vdots \\ &\sum_{\vec{z} \in \{0,1\}^l} (r_k^i(\vec{z}) - (q_k^i \circ r_{k_i+1}^i)(\vec{z}))^2 \approx 0 \end{aligned} \quad (11)$$

If all of these checks pass, the verifier will accept the claim.

B. Application to our problem

It is not very clear if the polynomial defined in Eq. (8) satisfies the conditions required by the previous construction.




Fig. 2: Our proposal to reduce certain high-degree sumchecks for approximate computations.

First of all, let's consider $p(X) \in \mathbb{R}[X]$ the real polynomial that approximates our nonlinear function f . As we will soon see, we will have to require p to be the composition of quadratic polynomials, which is something that classical methods (see [5]) do not guarantee. To be able to fulfill this requirement we will follow an iterative procedure that gradually composes degree 2 polynomials that minimize the error with respect to the function f . Then, the requirement imposed to p is satisfied by construction, and therefore we can assume $p = p_1 \circ \dots \circ p_m$, with p_i quadratic polynomials. An implementation of an algorithm that finds p given a function f and an error tolerance can be found here.

For simplicity, we can assume that the exponent Eq. (8) is $a = 2^n$. Then, consider $q_1(X) = \dots = q_n(X) = X^2$, and $q_{n+1}(X) = \frac{X^2}{\delta_2}$. As in Rmk. 2, we pick $F_1(X_1, \dots, X_l) := E(X_1, \dots, X_l)$ and $F_2(X_1, \dots, X_l) := -G(X_1, \dots, X_l)$, and then $F := (p_1 \circ \dots \circ p_m \circ F_1) + F_2$. We can now apply a degree reduction as described in Sec. III-A, with a big enough sampling set S , parameters $\delta_0 := L \cdot (\frac{\delta_1}{\delta_2})^a$, $\Delta_0 := (\frac{\delta_3}{\delta_2})^a$ and also δ, Δ chosen to guarantee completeness and soundness for an approximate sumcheck with a degree 4 polynomial.

IV. FUTURE WORK

Several components are left to future work: (i) principled parameter selection for (δ, Δ) , (ii) a practical instantiation strategy (noting that polynomial commitments over $\mathbb{R}$ are currently unavailable), and (iii) an empirical evaluation on common ML non-linearities to quantify prover overhead and

numerical fidelity. We believe that making approximation native to the proof protocol can offer an attractive alternative to VML when quantization is undesirable or when high numerical precision must be preserved.

ACKNOWLEDGEMENTS

This work is supported by the AEI-PID2021-128521OB-I00 grant of the Spanish Ministry of Science and Innovation, and Artemisa Chair, an initiative carried out within the framework of the funds of the Recovery, Transformation and Resilience Plan, financed by the European Union (Next Generation), the project of the Spanish Government that traces the roadmap for the modernization of the Spanish economy, the recovery of economic growth and job creation, for the solid, inclusive and resilient economic reconstruction after the COVID-19 crisis, and to respond the challenges of the next decade.

REFERENCES

- [1] Dor Bitan, Zachary DeStefano, Shafi Goldwasser, Yuval Ishai, Yael Tsa-man Kalai, and Justin Thaler: Sum-check protocol for approximate computations, *ePrint Archive*, Paper 2025/2152, 2025.
- [2] Thibault Feneuil and Matthieu Rivain: CAPSS: A Framework for SNARK-Friendly Post-Quantum Signatures, *ePrint Archive*, Paper 2025/061, 2025.
- [3] Eli Ben-Sasson, Alessandro Chiesa, and Nicholas Spooner: Interactive Oracle Proofs, *ePrint Archive*, Paper 2016/116, 2016.
- [4] Aniket Kate, Gregory M. Zaverucha, and Ian Goldberg: Constant-size commitments to polynomials and their applications, *Advances in Cryptology – ASIACRYPT 2010*, 2010.
- [5] Lloyd N. Trefethen: *Approximation Theory and Approximation Practice*, Society for Industrial and Applied Mathematics, 2019.

Sesión de Investigación 1 - Detección, prevención y respuesta

MadHoney: Señuelos Tóxicos para la Defensa Activa en el Aprendizaje Federado Descentralizado

Pedro Beltrán-López¹, Enrique Tomás Martínez Beltrán¹, Pantaleone Nespoli¹, Manuel Gil Pérez¹,
Gregorio Martínez Pérez¹, Alberto Huertas Celdrán¹

¹Departamento de Ingeniería de la Información y las Comunicaciones, Universidad de Murcia, 30100, España
Email: {pedro.beltranl, enriquetomas, pantaleone.nespoli, mgilperez, gregorio, alberto.huertas}@um.es

Resumen—El aprendizaje federado descentralizado (DFL) permite el entrenamiento colaborativo sin compartición de datos privados y sin servidores centrales, pero su naturaleza abierta lo hace vulnerable a ataques de envenenamiento semántico, especialmente puertas traseras persistentes. Este trabajo presenta MadHoney, una defensa proactiva basada en ciberengaño que opera a nivel de aplicación mediante un HoneyNode que audita la red inyectando información de control y generando trampas dinámicas e impredecibles. La propuesta combina: (i) generación de cebos mediante mapas caóticos y backdoors efímeros, (ii) diseminación selectiva con un modelo dual (limpio y señuelo) según la confianza, (iii) verificación semántica del comportamiento del vecino mediante métricas probabilísticas, y (iv) rastreo distribuido de la infección con pivote DFS y contención. En un entorno DFL en anillo (10 nodos, 150 rondas) sobre CIFAR-10 no-IID, MadHoney alcanza un F1-score de 0.683 ± 0.031 , comparable al escenario sin atacantes y superior al escenario atacado.

Index Terms—Ciberengaño, Aprendizaje federado descentralizado, Defensa activa, Señuelos dinámicos

Tipo de contribución: *Investigación original*

I. INTRODUCCIÓN

La ciberseguridad se ha convertido en un pilar crítico de la sociedad digital debido a la consolidación de infraestructuras distribuidas y críticas (IoT, servicios hiperconectados y sistemas colaborativos) y al incremento de amenazas capaces de operar de forma persistente y adaptativa [1]. En este contexto, la inteligencia artificial y el aprendizaje automático han impulsado mejoras sustanciales en la prevención, la detección y la respuesta frente a ciberamenazas [2]. Sin embargo, una parte relevante de los mecanismos defensivos continúan siendo estáticos o reactivos, apoyándose en reglas fijas, firmas, umbrales invariables o filtrados pasivos. Este enfoque resulta especialmente frágil frente a adversarios que ajustan su estrategia al identificar los patrones de defensa, degradando progresivamente la eficacia del sistema. De ahí surge el interés por defensas dinámicas y activas, capaces de inducir incertidumbre en el atacante y de forzar la exposición de comportamientos maliciosos mediante interacción controlada, siguiendo la filosofía del ciberengaño aplicada a nuevos dominios [3].

Uno de esos dominios emergentes es el aprendizaje federado (FL), donde varios nodos colaboran para detectar ciberataques de forma exitosa. En particular, FL permite entrenar modelos de forma colaborativa sin compartir datos crudos, lo que facilita escenarios con restricciones regulatorias y de privacidad [4]. No obstante, la misma descentralización y protocolos de DFL que protegen los datos amplía la superficie de ataque; es decir, participantes no confiables pueden manipular el entrenamiento local y enviar actualizaciones maliciosas (p.

ej., backdoors o envenenamiento dirigido) que preservan el rendimiento en entradas limpias y, simultáneamente, activan conductas adversarias bajo disparadores [5]. El problema se agrava en aprendizaje federado descentralizado (DFL), donde desaparece la figura del servidor agregador. La ausencia de un punto central de control confiable dificulta tanto la inspección global como la atribución del origen del ataque y la coordinación de contramedidas. Precisamente por ello, en topologías descentralizadas la defensa no debería limitarse a “filtrar” actualizaciones sospechosas, sino incorporar mecanismos de auditoría activa, atribución y contención distribuida [6].

En la literatura existente, la defensa frente a clientes maliciosos en FL/DFL se ha centrado mayoritariamente en mecanismos reactivos (p.ej., agregación robusta, filtrado estadístico u operadores de detección) que, aunque efectivos en determinados escenarios, suelen asumir coordinación central o una vista global del sistema. Por eso, este trabajo propone MadHoney, una defensa proactiva contra ataques de envenenamiento semántico diseñada para operar en la capa de aplicación de las redes que conectan los nodos que participan en el DFL. A diferencia de enfoques que actúan como filtros pasivos, MadHoney introduce el concepto de HoneyNode (i.e., un defensor activo), un agente autónomo que audita la integridad de la red mediante inyección estratégica de información de control y generación de trampas dinámicas y caóticas, volviendo la defensa impredecible y obligando al adversario a interactuar con “cebos” digitales para revelar su intención. Además, MadHoney completa el ciclo de seguridad con verificación y contención distribuida, evaluando el comportamiento real de los vecinos frente a trampas inyectadas para distinguir nodos benignos, portadores involuntarios (*carriers*) y atacantes activos, y habilitando acciones automáticas que trascienden el bloqueo (p. ej., rastreo de la infección a través de la topología para aislar el origen).

En particular, MadHoney introduce una defensa activa basada en ciberengaño que, en cada ronda, genera señuelos efímeros (válidos y activos únicamente durante una única ronda de comunicación) y cambiantes para auditar el comportamiento de los nodos sin interferir en el aprendizaje legítimo. Para evitar efectos colaterales, el sistema emplea una estrategia de doble modelo: uno orientado al entrenamiento normal y otro reservado para pruebas de integridad, distribuyéndolos de forma selectiva según el nivel de confianza del vecino. En lugar de basarse únicamente en inspecciones estáticas de parámetros, MadHoney verifica el comportamiento de los modelos recibidos mediante pruebas controladas que permiten detectar señales compatibles con envenenamiento o puertas traseras. Finalmente, dado que en DFL un ataque puede propa-

garse a través de nodos intermedios, la propuesta incorpora un mecanismo de rastreo y contención distribuida para localizar el origen y aplicar medidas de aislamiento y recuperación del estado global.

Las contribuciones de este trabajo pueden ser resumidas a continuación:

- La formalización de una defensa activa basada en ciberengaño para DFL mediante HoneyNode y trampas dinámicas caóticas.
- La proposición de un esquema de verificación semántica y atribución distribuida (DFS pivot) para distinguir benignos, carriers y atacantes.
- La validación empírica de la viabilidad en un entorno DFL estricto sin agregadores centrales, cuantificando utilidad y sobrecarga.

La estructura de este artículo es la siguiente. La Sección II revisa el estado del arte. La Sección III describe el diseño de MadHoney, incluyendo la generación de cebos, modelo dual, inferencia semántica, pivote DFS y contención. La Sección IV presenta el caso de uso y la evaluación experimental sobre DFL. La Sección V discute resultados cuantitativos. Finalmente, la Sección VI concluye y plantea líneas futuras.

II. ESTADO DEL ARTE

La defensa frente a participantes maliciosos en FL/DFL se ha abordado tradicionalmente con (i) agregadores robustos o filtrados estadísticos de actualizaciones, y (ii) mecanismos de detección de clientes adversarios. En los últimos años, además, han emergido propuestas que incorporan ideas de ciberengaño, trasladando al entrenamiento federado conceptos análogos a honeypots y decoys para inducir señales más separables del comportamiento malicioso.

En este sentido, FLDetector [7] propone detectar clientes maliciosos observando la inconsistencia multi-ronda de sus actualizaciones. El servidor predice la actualización esperable de cada cliente usando su historial y marca como malicioso a quien diverge repetidamente, permitiendo después aplicar agregación robusta sobre el subconjunto restante. Esta propuesta no depende únicamente de una foto fija por ronda, sino de un patrón temporal. No obstante, se asume un servidor central con capacidad de observación y modelado del historial de cada cliente.

FedGT [8] aborda el problema bajo *secure aggregation* mediante *group testing*, es decir, organiza clientes en grupos solapados, observa agregados por grupo y decodifica la presencia/identidad de maliciosos. Posteriormente, los elimina del entrenamiento, mostrando eficacia en varios datasets y ataques de envenenamiento. Aunque mejora el equilibrio entre privacidad y seguridad, su operación es también *server-driven* y se centra en identificación, no en contención topológica en redes sin servidor.

Adicionalmente, SafeFL [9] plantea un enfoque de detección conductual donde el servidor reúne una serie de modelos globales y genera un dataset sintético con el que diferencia modelos benignos de maliciosos por su comportamiento. El objetivo es reducir falsos positivos y evitar supuestos poco realistas sobre capacidades del servidor. Este planteamiento se aproxima a una auditoría por “sondeo”, pero sigue descansando en un coordinador central y no considera el rastreo distribuido de la propagación.

Por otra parte, ARMOR [12] introduce *differential model distribution*, distribuyendo modelos diferentes a distintos clientes para reducir la transferibilidad de ataques adversarios generados por clientes bizantinos, reforzando la robustez diferencial del sistema. Esta estrategia se orienta a robustez preventiva más que a identificación y contención del origen.

En la línea de ciberengaño explícito, HoneyFL [10] introduce clientes honeypot que insertan un HoneyDoor y utilizan un HoneyMap para atrapar ataques de backdoor durante el entrenamiento. Los autores usan además estrategias para dificultar ataques adaptativos alterando periódicamente cómo y dónde se generan las trampas (es decir, mediante políticas de inicialización o de estructura dinámica). De forma complementaria, HoneyFED [11] propone un modelo global de decoy (señuelo) para engañar y obstaculizar atacantes de poisoning, capturando patrones de ataque y diseñando un decoy creíble que induce al adversario a creer que ha tenido éxito. Estas propuestas muestran el potencial del engaño, pero típicamente se formulan para FL centralizado y no resuelven la atribución en paradigmas DFL.

En resumen, gran parte del estado del arte (i) asume un servidor central (o una vista global) para coordinar la detección, agrupación y sondeo; (ii) no modela explícitamente la propagación transitiva de la contaminación en DFL; y (iii) rara vez integra un ciclo completo de atribución, contención

Tabla I

COMPARATIVA DEL ESTADO DEL ARTE EN DETECCIÓN/MITIGACIÓN DE CLIENTES MALICIOSOS EN FL/DFL Y ENFOQUES BASADOS EN CIBERENGAÑO.

Trabajo	Mecanismo principal	Ataque objetivo	Engaño/sondeo	Identifica	DFL	Contención
FLDetector [7]	Consistencia multi-ronda	Poisoning	Sondeo temporal	Sí	No	No
FedGT [8]	Group testing + decodificación	Poisoning	Agrupación encubierta	Sí	No	No
SafeFL [9]	Dataset sintético para auditoría	Poisoning	Sondeo conductual	Sí	No	No
HoneyFL [10]	Honeypots (HoneyDoor/HoneyMap)	Backdoor	Sí	Sí	No	Parcial
HoneyFED [11]	Modelo decoy global	Poisoning	Sí	Parcial	No	Parcial
ARMOR [12]	Modelos diferenciados por cliente	Adv. transfer	Moving Target	No	No	No
MadHoney	Señuelos dinámicos + verificación semántica + rastreo distribuido	Backdoor, veneno semántico	Sí	Sí (incluye carriers)	Sí	Sí

y recuperación. En contraste, MadHoney se diseña para DFL estricto sin agregadores centrales y desplaza el foco desde la inspección de parámetros hacia la verificación semántica con trampas efímeras, incorporando además pivote DFS para rastreo de carriers y contención distribuida (aislamiento, reparación y saneamiento). En este sentido, la Tabla I compara los trabajos del estado del arte, evidenciando las características comunes.

III. DISEÑO DE MADHONEY

Esta sección presenta *MadHoney*, una defensa proactiva diseñada para operar en la capa de aplicación de las redes de DFL, enfocada específicamente en mitigar ataques de envenenamiento semántico y puertas traseras (*backdoors*) persistentes. A diferencia de los enfoques reactivos que filtran actualizaciones basándose en reglas fijas, *MadHoney* introduce un *HoneyNode* (Defensor Activo) que audita la red inyectando trampas dinámicas e impredecibles. Esta estrategia obliga a los adversarios a interactuar con “cebos” digitales, revelando sus intenciones maliciosas sin afectar el rendimiento de los nodos honestos.

Operativamente, el sistema se comporta como un ciclo de vida continuo de auditoría y respuesta. En cada ronda, el defensor genera un desafío efímero, lo disemina selectivamente entre sus vecinos y analiza semánticamente sus respuestas para distinguir comportamientos anómalos. Si se detecta una amenaza, el mecanismo no se limita a bloquear al vecino inmediato, sino que inicia un rastreo distribuido para localizar y aislar la fuente original del ataque, garantizando la recuperación de la federación.

La arquitectura que soporta este proceso se ilustra en la Figura 1. El bloque central actúa como el “cerebro” que coordina las cuatro fases fundamentales, conectadas por flechas que indican las comunicaciones efectivas que el defensor lleva a cabo a través de la topología:

1. **Generación de Mapa Caótico y Cebo:** El ciclo inicia en el bloque superior izquierdo, donde se crea un estado matemático impredecible para cada ronda. Esto permite

generar un “cebo” único y dinámico que impide a los atacantes aprender el patrón de defensa.

2. **Modelo Dual y Diseminación:** Siguiendo el flujo hacia abajo, el sistema decide qué enviar aplicando una estrategia dual: transmite un modelo limpio a los nodos confiables y un modelo trampa a los sospechosos. Las flechas salientes representan la inyección física de estos parámetros en la red para auditar a los vecinos.
3. **Métricas de Detección de Inferencia:** Cuando los modelos regresan de la red, el flujo entra al bloque superior derecho para el análisis. Aquí se calculan indicadores probabilísticos que determinan si el vecino absorbió el cebo, si intenta inyectar veneno o si se mantiene honesto.
4. **Pivote DFS y Contención:** Si el análisis detecta una amenaza, el ciclo deriva al bloque inferior derecho. Esta fase final ejecuta el rastreo del ataque a través de los nodos portadores para localizar su origen y aplica el aislamiento definitivo del culpable para proteger la federación.

Este flujo visual demuestra que la defensa no es estática, sino un proceso circular constante de ofrecer cebos, verificar respuestas en los medidores y limpiar la red mediante contención, garantizando así la recuperación automática y la resiliencia de la federación a largo plazo.

III-A. Generación de Mapa Caótico y Cebo

La robustez de un *honeypot* en el aprendizaje profundo depende de dos factores críticos: la indistinguibilidad del propio agente respecto a un nodo legítimo y la entropía del patrón de auditoría. Un esquema estático de verificación permitiría a un adversario adaptativo emplear técnicas de *unlearning* o de filtrado selectivo de gradientes para eludir la detección; es decir, si el atacante logra identificar un patrón de trampa recurrente, podría ajustar sus pesos para “desaprender” la respuesta maliciosa exclusivamente frente a ese estímulo, aparentando ser benigno durante la auditoría mientras mantiene el ataque activo en el resto de los casos. Para mitigar esta




Figura 1. Arquitectura funcional de MadHoney.

amenaza, se implementa un motor de generación de señuelos basado en *Mapas Caóticos Unidimensionales*, cuya evolución temporal se define mediante el Mapa Logístico (1):

$$\sigma_{t+1} = r \cdot \sigma_t \cdot (1 - \sigma_t) \quad (1)$$

donde $\sigma_t \in (0, 1)$ es el estado interno del generador en la ronda t , y $r = 3.99$ es el parámetro de control que garantiza la operación en el régimen caótico completo. El sistema es determinista dado el estado inicial σ_0 , pero computacionalmente impredecible para un adversario sin acceso a dicha semilla.

A partir del estado σ_t generado por (1), se construye una permutación de etiquetas $\pi_t : \mathcal{Y} \rightarrow \mathcal{Y}$ que asigna a cada clase original una etiqueta señuelo distinta, como se define en (2):

$$y' = \pi_t(y) = (y + \lfloor \sigma_t \cdot |\mathcal{Y}| \rfloor + 1) \pmod{|\mathcal{Y}|} \quad (2)$$

donde $y \in \mathcal{Y}$ es la etiqueta original de la muestra, $|\mathcal{Y}|$ es el número total de clases, $\lfloor \cdot \rfloor$ denota la función suelo, y el término $+1$ garantiza matemáticamente que $y' \neq y$ para todo y . La permutación π_t varía en cada ronda, lo que hace inviable el filtrado estático para un adversario adaptativo.

Simultáneamente, se superpone un patrón disparador de alta entropía Δ acotado en la norma ($\|\Delta\|_\infty \leq \epsilon$) al espacio de entrada. Combinando la reetiquetación de (2) con este disparador, el conjunto de datos trampa para la ronda t queda definido según (3):

$$\mathcal{D}_{\text{trap}}^{(t)} = \{(x \oplus \Delta, y') \mid (x, y) \in \mathcal{D}_{\text{benign}}\} \quad (3)$$

donde $x \in \mathcal{X}$ es la muestra de entrada original, $\mathcal{D}_{\text{benign}}$ es el conjunto de datos benignos de MadHoney, Δ es el patrón disparador aditivo, y $\oplus$ denota la superposición del disparador sobre la imagen. Al entrenarse sobre $\mathcal{D}_{\text{trap}}^{(t)}$, el modelo aprende un *backdoor* controlado $\mathcal{C}_t : (x \oplus \Delta) \rightarrow y'$, que actúa como *token de validación efímero*, único para cada ronda de auditoría.

III-B. Modelo Dual y Diseminación

Un riesgo central en las defensas activas es el “fuego amigo”, es decir, la contaminación inadvertida de nodos honestos por los gradientes del señuelo. Para prevenirlo, MadHoney mantiene dos vectores de parámetros independientes:

- **θ_{clean} (Confiable):** entrenado exclusivamente con datos benignos $\mathcal{D}_{\text{benign}}$. Preserva la utilidad de la tarea principal y garantiza que MadHoney contribuya positivamente a la convergencia global cuando interactúa con nodos de confianza verificada.
- **θ_{bait} (Sospechoso):** bifurcación del modelo global sometida a *fine-tuning* intencional sobre $\mathcal{D}_{\text{trap}}^{(t)}$ (3) durante η_{bait} épocas locales, implantando el *backdoor* controlado $\mathcal{C}_t$.

El protocolo de transmisión implementa una diseminación selectiva basada en la reputación del vecino receptor. Sea $\mathcal{N}$ el conjunto de vecinos de MadHoney y $\mathcal{T}(n_j)$ el nivel de confianza asignado al nodo n_j . La función de transmisión Ψ_{tx} determina el payload según (4):

$$\Psi_{\text{tx}}(n_j) = \begin{cases} \theta_{\text{clean}} & \text{si } \mathcal{T}(n_j) \in \{\text{VERIFIED, TRUSTED}\} \\ \theta_{\text{bait}} & \text{si } \mathcal{T}(n_j) \in \{\text{UNKNOWN, SUSPECT}\} \\ \emptyset & \text{si } \mathcal{T}(n_j) = \text{MALICIOUS} \end{cases} \quad (4)$$

donde θ_{clean} es el modelo legítimo, θ_{bait} es el modelo señuelo con el *backdoor* $\mathcal{C}_t$ implantado, y $\emptyset$ indica que no se transmite payload alguno. Este mecanismo transforma a MadHoney en una entidad dual: agrega honestamente con nodos verificados y despliega una trampa activa para nodos desconocidos, forzándolos a revelar sus intenciones mediante su respuesta a θ_{bait} .

III-C. Métricas de Detección de Inferencia

Las métricas basadas en distancia Euclidiana o similitud coseno sobre pesos ∇w han demostrado insuficiencia frente a ataques de envenenamiento sofisticados. La propuesta actual sustituye la inspección de parámetros por la *Verificación de Comportamiento Semántico*: los modelos recibidos θ_{rx} son evaluados sobre el conjunto de validación trampa $\mathcal{V}_{\text{trap}}$, derivando tres métricas probabilísticas.

- **Tasa de Conformidad – Absorción (CR):** mide si el vecino absorbió el *backdoor* controlado $\mathcal{C}_t$, prediciendo la etiqueta señuelo y' codificada en (2) ante la presencia del disparador Δ :

$$\text{CR}(\theta_{\text{rx}}) = P(\hat{y} = y' \mid x \oplus \Delta; \theta_{\text{rx}}) \quad (5)$$

donde $\hat{y}$ es la predicción del modelo analizado, y' es la etiqueta señuelo definida por π_t , y $x \oplus \Delta$ es la muestra de validación con el disparador superpuesto.

- **Tasa de Sospecha - Malicioso (SR):** captura la probabilidad de que el modelo analizado prediga una clase objetivo de ataque k distinta tanto de la etiqueta original y como de la etiqueta señuelo y' , según (6):

$$\text{SR}(\theta_{\text{rx}}) = \max_{k \in \mathcal{Y} \setminus \{y, y'\}} P(\hat{y} = k \mid x \oplus \Delta; \theta_{\text{rx}}) \quad (6)$$

donde $\mathcal{Y} \setminus \{y, y'\}$ es el conjunto de clases excluidas la clase real y la señuelo, y $\max$ extrae la clase más probable dentro de dicho conjunto. Un valor elevado de SR combinado con $\text{CR} \approx 0$ es firma inequívoca de un *backdoor* adversario activo: el vecino filtra el cebo y redirige la predicción a su propio objetivo malicioso.

- **Tasa de Honestidad - Resistente (HR):** evalúa la robustez del modelo ante el disparador Δ , midiendo si es capaz de ignorar la perturbación y clasificar correctamente la clase original (7):

$$\text{HR}(\theta_{\text{rx}}) = P(\hat{y} = y \mid x \oplus \Delta; \theta_{\text{rx}}) \quad (7)$$

donde y es la etiqueta verdadera de la muestra. Un HR elevado indica que el nodo, aunque recibió el disparador, mantiene su comportamiento de clasificación original: señal de robustez defensiva o ausencia de infección.

III-D. Pivote DFS y Contención

El cierre del ciclo de MadHoney requiere determinar qué acción de mitigación o contención ejecutar dada una evaluación semántica (CR, SR, HR). Esta decisión se complica en topologías DFL descentralizadas debido a la propiedad de transitividad del envenenamiento, donde el veneno no fluye directamente del atacante a todos los nodos, sino a través de la estructura de vecindad. MadHoney puede detectar una señal de sospecha elevada ($SR > 0$) en un vecino n_j que no es el atacante original, sino un *Carrier* (un nodo intermediario que retransmite el modelo contaminado de forma involuntaria). Si n_j es un *Carrier*, el origen real pertenece a su vecindario de entrada $\mathcal{N}(n_j)$; por ejemplo, aplicar una contención inmediata (bloqueo) sobre este intermediario sería ineficaz, ya que el verdadero atacante seguiría inyectando veneno desde una posición oculta “aguas arriba”.

Para abordar este problema de atribución de fuente sin servidores centrales, se definen dos estrategias fundamentales:

Rastro de Veneno y Pivoteo (DFS): Si se identifica un nodo *Carrier*, el sistema debe remontar la cadena de infección. MadHoney ejecuta un *pivoteo de rol*, transfiriendo su estado interno ($\sigma_t, \mathcal{H}, \theta_{\text{bait}}$) al nodo *Carrier*. Este nodo asume temporalmente el rol de auditor (*HoneyNode*) y repite la auditoría de sus propios vecinos en la siguiente ronda, creando una búsqueda en profundidad Depth-First Search (DFS) distribuida, que permite rastrear el camino de la infección nodo a nodo hasta su origen.

Mecanismos de Contención: Cuando el rastreo alcanza al nodo origen n_{adv} (identificado por filtrar el cebo activamente, $CR \approx 0 \wedge SR > \tau_{\text{susp}}$), se ejecutan tres primitivas de seguridad en paralelo:

1. **Aislamiento:** Se difunde el mensaje de control $\text{BLOCK\_FLOOD}(ID_{\text{rx}})$ mediante protocolo *gossip*, alcanzando todos los nodos de la federación excepto el propio atacante. Cada nodo receptor actualiza su lista de control de acceso, rechazando futuros modelos y mensajes provenientes de n_{adv} .
2. **Puente de Recuperación:** Según la topología, el bloqueo de n_{adv} puede particionar la red. MadHoney identifica los vecinos directos de n_{adv} en el lado opuesto del anillo y establece conexiones directas con ellos, restaurando la conectividad sin reconfigurar la topología global.
3. **Saneamiento del modelo:** Dado que los pesos envenenados ya han sido absorbidos, el bloqueo no es suficiente. Se activa una de dos estrategias:
 - **Reseteo global:** Reinicialización de pesos y nueva fase de propagación.
 - **Entrenamiento de choque:** Se multiplica la tasa de aprendizaje por $5\times$ y las épocas locales por $3\times$ durante $R_{\text{shock}} = 10$ rondas para sobrescribir los gradientes residuales.

III-E. Ciclo de Vida de MadHoney

El mecanismo de defensa opera como un autómata de estados finitos que orquesta los módulos de inferencia y las estrategias de control. El ciclo completo, desde la activación de la trampa hasta la restauración de la red, se ejecuta en cinco fases secuenciales definidas en el Algoritmo 1:

1. **Inicialización y Generación de la Trampa:** Al inicio de la ronda t , MadHoney actualiza su estado interno mediante el mapa logístico σ_{t+1} (1). Con este estado, genera dinámicamente una permutación de etiquetas π_t y un disparador Δ . Se entrena localmente el modelo señuelo θ_{bait} para que aprenda el backdoor controlado $\mathcal{C}_t$, convirtiéndose en un token de validación único para esa ronda.
2. **Despliegue de Cebos:** MadHoney aplica la función de transmisión selectiva Ψ_{tx} (4). A los vecinos con reputación *VERIFIED* les envía el modelo limpio θ_{clean} para mantener la convergencia global. A los vecinos no verificados (*UNKNOWN* o *SUSPECT*) les inyecta θ_{bait} , forzándolos a interactuar con el backdoor controlado.
3. **Inferencia Semántica y Auditoría:** Tras recibir los modelos actualizados θ_{rx} de sus vecinos, el algoritmo somete a cada uno al dataset de validación $\mathcal{V}_{\text{trap}}$. Se computan las métricas de Conformidad, Sospecha y Honestidad (CR, SR, HR) para diagnosticar el estado del vecino.
4. **Ramificación de Control:** Basándose en las métricas calculadas, el sistema toma una de tres rutas críticas que se corresponden directamente con los bloques condicionales del algoritmo:
 - **Detección del Origen (MALICIOUS):** Si se confirma al atacante ($SR > \tau_{\text{susp}}, CR \approx 0$), se detiene el rastreo y se activa inmediatamente la Fase 5 (Contención).
 - **Pivoteo Recursivo (CARRIER):** Si se detecta un portador ($SR > 0, CR > 0$), MadHoney deduce que el origen del ataque está “aguas arriba”. Transfiere su estado ($\sigma_t, \mathcal{H}, \theta_{\text{bait}}$) al nodo *Carrier*. Este asume el rol de auditor y repite el proceso en la siguiente ronda (DFS), trazando la infección hacia su fuente.
 - **Verificación (BENIGN):** Si $HR > \tau_{\text{honest}}$, el vecino es honesto. Se actualiza su reputación a *VERIFIED*, garantizando que en el futuro reciba modelos limpios. El ciclo termina para este nodo.
5. **Contención y Saneamiento de la Red:** Una vez identificado el nodo n_{adv} , se ejecutan las primitivas de cierre:
 - **Aislamiento:** Se difunde BLOCK_FLOOD para expulsar al atacante de la topología.
 - **Reparación:** Se ejecuta *Recovery Bridge* para reconectar los vecinos del atacante y evitar particiones en el grafo.
 - **Limpieza:** Se dispara el entrenamiento de choque o reseteo global, dejando la red limpia para la siguiente ronda.

IV. CASO DE USO Y EVALUACIÓN EXPERIMENTAL

El escenario diseñado para evaluar la viabilidad y resiliencia del mecanismo de defensa MadHoney se desarrolla en un entorno DFL, caracterizado por la ausencia absoluta de servidores centrales de agregación. Para aislar el rendimiento topológico y evaluar cuantitativamente la capacidad del sistema frente a amenazas adversarias, se han instanciado variables

Algorithm 1 Pivoteo Recursivo DFS y Contención Distribuida de MadHoney

Require: Vecindario $\mathcal{N}$, historial $\mathcal{H}$, estado caótico σ_t (1), θ_{rx} , $\mathcal{V}_{trap}$, umbrales τ_{susp} , ϵ , τ_{honest}

Ensure: Acción de control $\mathcal{A}$

// Paso 1: Inferencia Semántica

1: $(CR, SR, HR) \leftarrow \text{Infer}(\theta_{rx}, \mathcal{V}_{trap})$ $\triangleright$ 5, 6, 7

// Paso 2: Clasificar el vecino y actuar

2: **if** $SR > \tau_{susp} \wedge CR < \epsilon$ **then**

 // Caso 1: Atacante detectado (MALICIOUS).

3: **Broadcast** BLOCK_FLOOD(ID_{rx}) $\triangleright$ Aislar n_{adv}

4: **Connect**(Neighbors(n_{adv})) $\triangleright$ Recovery Bridge

5: **Trigger** RESET **or** ShockTraining($5 \times LR, \dots$)

6: **return** CONTAINMENT

7: **else if** $SR > 0 \wedge CR > 0$ **then**

 // Caso 2: Portador detectado (CARRIER).

8: **if** $ID_{rx} \notin \mathcal{H}$ **then**

9: $\mathcal{H} \leftarrow \mathcal{H} \cup \{ID_{rx}\}$

10: **Transfer** ($\sigma_t, \mathcal{H}, \theta_{bait}$) $\rightarrow ID_{rx}$ $\triangleright$ DFS Pivot

11: **return** PIVOT_To(ID_{rx})

12: **else**

13: **return** STAY $\triangleright$ Evitar ciclos

14: **end if**

15: **else if** $HR > \tau_{honest}$ **then**

 // Caso 3: Nodo benigno (BENIGN).

16: $\mathcal{T}(ID_{rx}) \leftarrow \text{VERIFIED}$ $\triangleright$ Usar θ_{clean} (4)

17: **return** STAY

18: **else**

19: **return** STAY $\triangleright$ Monitoreo continuo

20: **end if**

de control relativas a la estructura de la red, la heterogeneidad de los datos y la persistencia temporal del ataque.

IV-A. Topología de Red y Configuración Federada

Se despliega una estructura estática basada en una topología de anillo (*Ring topology*), conformada por un total de $N = 10$ nodos activos. En este marco de conectividad, cada nodo n_i establece enlaces lógicos de comunicación bidireccional exclusivamente con sus dos vecinos adyacentes lógicos $n_{(i-1)}$ (mód N) y $n_{(i+1)}$ (mód N). La elección de una topología de anillo se fundamenta en su alta susceptibilidad a la desconexión frente a fallos y en sus rutas de propagación máximas (diámetro del grafo equivalente a $N/2$). Esta restricción impone un entorno de prueba riguroso para la primitiva de puente de recuperación (*Recovery Bridge*) de MadHoney, garantizando empíricamente que el aislamiento de un nodo atacante no fragmente la red. La federación opera durante $T = 150$ rondas globales, un parámetro temporal establecido para asegurar la captura de la convergencia asintótica del modelo y la efectividad de las estrategias de mitigación.

Como función de consenso, se implementa el algoritmo de FedAvg. La selección de FedAvg, por encima de agregadores inherentemente robustos frente a la tolerancia a fallos bizantinos como Krum o medias recortadas, obedece a un objetivo analítico específico: al ser una métrica de promediado lineal, carece de defensas estadísticas nativas. Esto permite cuantificar de manera aislada la eficacia de la lógica de defensa activa inyectada por los nodos señuelo, validando que

el enfoque semántico de MadHoney protege eficientemente incluso los protocolos de agregación más vulnerables.

IV-B. Conjunto de Datos y Arquitectura del Modelo

La validación empírica emplea el conjunto de datos de visión artificial CIFAR-10, compuesto por 60 000 imágenes a color de 32×32 píxeles, distribuidas equitativamente en diez clases. Para emular el desequilibrio estadístico inherente a los entornos de *Edge Computing*, las muestras de entrenamiento se distribuyen de forma no independiente e idénticamente distribuida (Non-IID) entre los diez participantes. La partición se ejecuta aplicando una distribución de Dirichlet con un parámetro de concentración $\alpha = 0.5$. Este valor induce un sesgo semántico severo en el que cada nodo posee ejemplos predominantemente de una minoría de clases. Dicha heterogeneidad fuerza una divergencia paramétrica natural en los gradientes locales ∇w , escenario que neutraliza la eficacia de los sistemas de defensa pasivos basados en similitud coseno o distancia Euclidiana, y demuestra la necesidad de las métricas de evaluación de comportamiento semántico propuestas.

V. RESULTADOS

Para la tarea de extracción de características, se instancia una Red Neuronal Convolutiva (CNN) adaptada al espacio dimensional de CIFAR-10. La arquitectura se compone de tres bloques convolucionales secuenciales configurados con 32, 64 y 128 filtros receptivos de 3×3 . Cada bloque integra de manera estándar capas de normalización por lotes (*Batch Normalization*) y agrupación máxima (*Max Pooling* de 2×2). Las representaciones latentes se vectorizan hacia dos capas densas (*Fully Connected*) de 512 y 10 neuronas, utilizando una función de activación *Softmax* en la salida. Esta capacidad paramétrica garantiza un balance óptimo entre la eficiencia computacional demandada por el DFL y la complejidad necesaria para modelar simultáneamente la tarea principal y los *backdoors* efímeros de auditoría.

V-A. Modelo de Amenaza: Puerta Trasera Dirigida

La resiliencia de la red se somete a prueba mediante la inducción de un vector de ataque malicioso. Al inicio del proceso (ronda $t = 1$), se compromete de manera aleatoria un (1) nodo dentro de la topología, estableciendo una proporción de atacantes inicial del 10%. Este adversario ejecuta un ataque de puerta trasera (*backdoor attack*) semántico persistente: superpone un patrón de ruido determinista (*trigger*) en una proporción de sus muestras locales y altera sus etiquetas para forzar la predicción hacia la clase número 4 (*cat*).

El objetivo del ataque es subvertir el modelo global para que clasifique invariablemente como “gato” cualquier entrada que contenga el disparador, manteniendo una precisión estándar sobre datos prístinos para evadir la detección algorítmica. La ejecución ininterrumpida desde la primera iteración persigue la consolidación del gradiente malicioso en las fases tempranas de convergencia, exigiendo a MadHoney detectar rápidamente si un nodo adversario está descartando o ignorando intencionadamente los cebos (filtrado), para poder aislar a ese atacante antes de que la infección se propague por toda la red.

V-B. Plataforma de Despliegue: NEBULA

La orquestación, simulación topológica y monitorización de las iteraciones se ejecutan sobre NEBULA [5], una plataforma de código abierto concebida específicamente para el entrenamiento y gestión de redes DFL en dispositivos físicos y virtualizados. La integración con NEBULA se fundamenta en su arquitectura modular topológicamente agnóstica, la cual permite forzar la estructura de anillo de manera estricta mediante conexiones *Peer-to-Peer* (P2P). El componente *Controller* de NEBULA proporciona las herramientas analíticas para evaluar dinámicamente el impacto de la defensa. La infraestructura permite monitorizar de forma paralela la precisión funcional de la tarea principal mediante la métrica F_1 -score durante todo el proceso federado. La implementación técnica del protocolo defensivo dentro de la capa *Core* de NEBULA (desarrollada en Python) valida la viabilidad operativa de MadHoney y su capacidad de extensión directa a escenarios industriales o de Internet de las Cosas (IoT).

La presente evaluación experimental tiene como propósito fundamental verificar si la arquitectura MadHoney satisface tres propiedades críticas de seguridad operativa en entornos de DFL: (i) la preservación de la utilidad del modelo global bajo ataques semánticos activos, (ii) la contención topológica de la propagación maliciosa sin inducir la degradación estructural de los nodos benignos, y (iii) la viabilidad en el consumo de recursos computacionales y de red, particularmente en topologías de anillo (*Ring*) caracterizadas por su alta susceptibilidad a la partición de red. Consecuentemente, los hallazgos proporcionan evidencia empírica sobre la eficacia del ciclo de vida integral del sistema, el cual abarca la generación caótica de cebos, la inferencia semántica, el pivoteo de búsqueda en profundidad (DFS) y los protocolos de contención.

La dinámica temporal de convergencia, analizada a lo largo de 150 rondas de comunicación e ilustrada en la Figura 2, exhibe divergencias significativas entre los escenarios evaluados. En el escenario de vulnerabilidad base (*Attack*),

la federación experimenta una dispersión acentuada en las trayectorias de aprendizaje de los nodos individuales y una degradación severa inducida por el nodo comprometido. Este comportamiento subraya la capacidad destructiva del envenenamiento semántico para desestabilizar la convergencia global en ausencia de mecanismos de defensa proactivos.

Por su parte, la implementación de la defensa sin saneamiento paramétrico, denominada *MadHoney (No Global Reset)*, muestra indicios de contención parcial temprana; sin embargo, se observa la persistencia de un arrastre de contaminación (gradientes residuales envenenados) que penaliza de forma irreversible el rendimiento asintótico del modelo. En contraste, el escenario *MadHoney (Global Reset)* demuestra una recuperación estructural limpia y sostenida. En esta configuración, la trayectoria de convergencia final se alinea casi simétricamente con el escenario de control sin atacantes (*Baseline*). Este fenómeno valida la hipótesis de diseño principal: la detección precisa del vector malicioso debe acoplarse obligatoriamente con un saneamiento global para erradicar la persistencia de gradientes tóxicos y restaurar la utilidad del conocimiento colectivo.

Los resultados cuantitativos, detallada en la Tabla II, corroboran esta interpretación. Al evaluar exclusivamente a los nodos honestos en entornos hostiles, *MadHoney (Global Reset)* logra el desempeño óptimo con un F1-score final de 0.683 ± 0.031 . Este resultado representa una mejora relativa del 21.9% frente al escenario *Attack* (0.560 ± 0.192) y establece una paridad estadística con el entorno ideal *Baseline* (0.680 ± 0.030). Adicionalmente, la reducción drástica en la desviación estándar final respecto al escenario de ataque directo sugiere una restauración robusta de la homogeneidad internodo posterior a la fase de contención. Inversamente, la estrategia *MadHoney (No Global Reset)* finaliza con un F1-score deficiente de 0.494 ± 0.094 , confirmando matemáticamente que el aislamiento del atacante es una condición necesaria, pero insuficiente, si no se purga la memoria paramétrica de




Figura 2. Evolución temporal del F1-score por participante a través de los cuatro escenarios experimentales durante 150 rondas de federación.

Tabla II

RESUMEN CUANTITATIVO POR ESCENARIO (MEDIA $\pm$ DESVIACIÓN ESTÁNDAR). EN ESCENARIOS CON ATACANTE, LAS ESTADÍSTICAS DE RENDIMIENTO SE CALCULAN EXCLUSIVAMENTE SOBRE LOS NODOS HONESTOS.

Escenario	F1-score	CPU proceso (%)	RAM proceso (MB)	Δ TX (MB/ronda)	Δ RX (MB/ronda)
Baseline (10 honestos)	0.680 ± 0.030	202.31 ± 11.47	1407.7 ± 33.8	4.039 ± 0.468	4.022 ± 0.471
Attack (9 honestos)	0.560 ± 0.192	210.49 ± 12.65	1427.6 ± 36.9	4.040 ± 0.448	4.022 ± 0.437
MadHoney (No Global Reset, 9 honestos)	0.494 ± 0.094	140.76 ± 26.54	1417.0 ± 33.2	4.472 ± 0.508	4.439 ± 0.484
MadHoney (Global Reset, 9 honestos)	0.683 ± 0.031	129.76 ± 26.95	1404.2 ± 31.1	4.474 ± 0.515	4.437 ± 0.477

la federación.

Desde la perspectiva del coste operativo (Tabla II), la instrumentación de la defensa no impone una sobrecarga computacional prohibitiva que limite su aplicabilidad en la frontera (*Edge Computing*). Resulta contraintuitivo, pero justificable, que ambas variantes de MadHoney exhiban un consumo medio de CPU sustancialmente inferior al escenario *Attack* (disminuyendo de 210.49 % a 129.76 % en la configuración *Global Reset*). Esta eficiencia térmica se atribuye a la expulsión temprana del nodo malicioso, lo que previene el desperdicio de ciclos de reloj en la computación de gradientes sobre modelos globales altamente divergentes y corruptos. El consumo de memoria RAM se mantiene estable a través de todos los escenarios, demostrando que la gestión dual de parámetros (θ_{clean} y θ_{bait}) está optimizada.

Finalmente, se registra un incremento marginal en la huella de red ($\Delta\text{TX}/\Delta\text{RX}$) de aproximadamente 0.43 MB/ronda en los entornos defendidos. Este *overhead* comunicacional es una consecuencia directa y esperada de la diseminación selectiva de modelos trampa, la propagación de metadatos de estado para el DFS y los mensajes de *gossip* utilizados en el aislamiento (*BLOCK_FLOOD*). No obstante, este coste extra en el ancho de banda constituye un compromiso (*trade-off*) altamente favorable, dado que habilita una restauración íntegra de la resiliencia del sistema de aprendizaje colectivo.

VI. CONCLUSIONES

Este trabajo presenta MadHoney, una defensa activa basada en ciberengaño contra el envenenamiento semántico en redes de aprendizaje federado descentralizado. Mediante un HoneyNode, el sistema inyecta trampas dinámicas y emplea un modelo dual para exponer nodos maliciosos sin penalizar el aprendizaje legítimo. Además, integra verificación de comportamiento y un mecanismo de rastreo distribuido para localizar, aislar y mitigar el ataque original.

La evaluación experimental en un escenario DFL en anillo (10 nodos, 150 rondas) sobre CIFAR-10 no-IID muestra que, ante ataques persistentes de tipo backdoor, MadHoney es capaz de recuperar de forma significativa la utilidad del aprendizaje colectivo cuando se acompaña de un proceso de saneamiento posterior, situando el rendimiento global cerca del escenario sin atacantes. Asimismo, los resultados evidencian que el aislamiento del atacante, por sí solo, puede resultar insuficiente si no se aborda la contaminación residual acumulada en rondas previas, lo que refuerza la necesidad de integrar capacidades de recuperación dentro del ciclo defensivo. En términos de coste, la solución introduce un incremento de comunicación acotado, compatible con escenarios distribuidos y entornos edge, a cambio de incorporar auditoría activa y atribución. Asimismo, el diseño basado en una arquitectura de modelo dual ha demostrado ser efectivo para evitar el 'fuego amigo', mitigando así el riesgo de contaminación accidental del sistema por parte de los propios señuelos defensivos.

Como líneas de trabajo futuras, resulta especialmente relevante estudiar la escalabilidad del sistema extendiendo la evaluación a topologías DFL de mayor tamaño y a redes dinámicas con conectividad intermitente. Además, es necesario ampliar el modelo de amenaza para analizar el comportamiento del sistema frente a adversarios adaptativos avanzados que decidan eludir deliberadamente la interacción con el cebo,

así como escenarios con múltiples atacantes. Finalmente, dado que la estrategia de reseteo global puede resultar poco realista en infraestructuras de sistemas críticos, se considera prioritario explorar mecanismos de saneamiento menos disruptivos que aceleren la recuperación sin comprometer la estabilidad del modelo ni aumentar el riesgo de contaminación accidental del sistema.

AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por (a) la Comisión Europea, a través del proyecto Horizon Europe/JU SNS ROBUST-6G (Grant Agreement n.º 101139068), (b) MCIN/AEI/10.13039/501100011033/FEDER, bajo la subvención PID2021-122466OB-I00 (REACTMAN), y (c) la Oficina Federal Suiza de Adquisiciones de Defensa (armasuisse) mediante el proyecto TITAN.

REFERENCIAS

- [1] P. Nespoli, D. Useche Pelaez, D. Díaz López, and F. Gómez Mármol, "Cosmos: Collaborative, seamless and adaptive sentinel for the internet of things," *Sensors*, vol. 19, no. 7, 2019. [Online]. Available: <https://www.mdpi.com/1424-8220/19/7/1492>
- [2] P. Nespoli, S. Bernardez Molina, P. Beltrán-López, and F. Gómez Mármol, "Tackling cyberattacks through ai-based reactive systems: A holistic review and future vision," *IEEE Communications Surveys & Tutorials*, vol. 28, pp. 1557–1596, 2026.
- [3] P. Beltrán-López, M. Gil Pérez, and P. Nespoli, "Cyber deception: Taxonomy, state of the art, frameworks, trends, and open challenges," *IEEE Communications Surveys & Tutorials*, vol. 28, pp. 1520–1556, 2026.
- [4] E. T. Martínez Beltrán, P. M. S. Sánchez, G. Bovet, B. Stiller, G. M. Pérez, and A. H. Celdrán, "Flighter: Decentralized federated learning and situational awareness for secure military aerial reconnaissance," *IEEE Communications Magazine*, vol. 63, no. 10, pp. 136–142, 2025.
- [5] E. T. Martínez Beltrán, G. Bovet, G. M. Pérez, and A. H. Celdrán, "Nebula - decentralized federated learning for heterogeneous networks," in *Proceedings of the ACM SIGCOMM 2025 Posters and Demos*, ser. ACM SIGCOMM Posters and Demos '25. New York, NY, USA: Association for Computing Machinery, 2025, p. 149–151. [Online]. Available: <https://doi.org/10.1145/3744969.3748413>
- [6] E. T. Martínez Beltrán, M. Q. Pérez, P. M. S. Sánchez, S. L. Bernal, G. Bovet, M. G. Pérez, G. M. Pérez, and A. H. Celdrán, "Decentralized federated learning: Fundamentals, state of the art, frameworks, trends, and challenges," *IEEE Communications Surveys & Tutorials*, vol. 25, no. 4, pp. 2983–3013, 2023.
- [7] Z. Zhang, X. Cao, J. Jia, and N. Z. Gong, "Fldetector: Defending federated learning against model poisoning attacks via detecting malicious clients," in *KDD '22: The 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining, Washington, DC, USA, August 14 - 18, 2022*, A. Zhang and H. Rangwala, Eds. ACM, 2022, pp. 2545–2555. [Online]. Available: <https://doi.org/10.1145/3534678.3539231>
- [8] M. Xhemrishi, J. Östman, A. Wachter-Zeh, and A. G. i Amat, "Balancing privacy and security in federated learning with fedgt: A group testing framework," *CoRR*, vol. abs/2305.05506, 2023. [Online]. Available: <https://doi.org/10.48550/arXiv.2305.05506>
- [9] Z. Dou, J. Wang, W. Sun, Z. Liu, and M. Fang, "Toward malicious clients detection in federated learning," *CoRR*, vol. abs/2505.09110, 2025. [Online]. Available: <https://doi.org/10.48550/arXiv.2505.09110>
- [10] H. Zheng, W. Shen, and J. Chen, "Honeyfl: Using honeypots to catch backdoors in federated learning," *IET Image Processing*, 2025, early access / Online first. [Online]. Available: <https://doi.org/10.1049/ipr2.70201>
- [11] G. C. T. Masse, A. Benslimane, V. K. Tchendji, A. H. A. Hemida, Z. Su, and S. Han, "Deception-based defense against model poisoning attacks in federated learning using generative adversarial network (GAN)," in *IEEE International Conference on Communications, ICC 2025, Montreal, QC, Canada, June 8-12, 2025*. IEEE, 2025, pp. 4933–4938. [Online]. Available: <https://doi.org/10.1109/ICC52391.2025.11161880>
- [12] Y. Zhang, J. Liu, Z. Guan, B. Zhao, X. Leng, and S. Bian, "Armor: Differential model distribution for adversarially robust federated learning," *Electronics*, vol. 12, no. 4, p. 842, 2023. [Online]. Available: <https://doi.org/10.3390/electronics12040842>

Hybrid Physics-Informed Neural Network (PINN) for Stealthy FDI Detection

Mohammadhossein Homaei, Agustín Di Bartolo, Alberto Lopez Trigo, Pablo García Rodríguez, and Mar Avila

Grupo de Ingeniería de Medios, Universidad de Extremadura,
Cáceres, Spain

mhomaein@alumnos.unex.es, {adibartolo, albertolt, pablogr, mmavila}@unex.es

Abstract—Standard data-driven anomaly detection methods in Industrial Control Systems (ICS) often lack interpretability and remain vulnerable to stealthy False Data Injection (FDI) attacks that mimic normal operational behavior. While Physics-Informed Neural Networks (PINNs) improve modeling reliability by embedding physical constraints, they typically rely on fixed parameters and cannot fully capture system aging, sensor drift, or unmodeled dynamics, creating a reality gap. This paper proposes the Adaptive Graph Physics-Informed Neural Network (AG-PINN), which integrates real-time system identification with anomaly detection. The architecture jointly learns system states and estimates latent physical coefficients using a Graph Attention encoder derived from plant P&ID structure and a Differentiable Physics Layer. Physical parameters are periodically recalibrated using a 24-hour sliding window, with rate-of-change constraints applied to prevent adversarial manipulation. The model is trained using a dual-objective loss balancing prediction accuracy and physical residual minimization. Experiments on SWaT and WADI datasets show that AG-PINN achieves an F1-Score of 0.971, reduces the False Positive Rate to 0.08%, and improves stealthy attack detection recall by 23.1 percentage points compared with the best baseline.

Index Terms—False Data Injection Detection, Physics-Informed Neural Networks, Graph Attention Networks, Industrial Control Systems, Adaptive System Identification

I. INTRODUCTION

The growing adoption of IoT devices in Industrial Control Systems (ICS) has expanded the attack surface of critical infrastructure, including water treatment facilities, power grids, and chemical plants [1], [2]. The convergence of Information Technology (IT) and Operational Technology (OT) has introduced vulnerabilities that sophisticated adversaries can exploit [3]. Among the most concerning threats are *False Data Injection (FDI)* attacks, in which an adversary compromises sensor measurements to mislead control logic and drive the physical process toward unsafe conditions. Real-world incidents such as the Stuxnet attack and the 2015 Ukraine power grid intrusion have demonstrated that these threats carry devastating consequences for public safety and economic stability [4], [5]. The Secure Water Treatment (SWaT) and Water Distribution (WADI) datasets from iTrust, Singapore University of Technology and Design, have become widely adopted benchmarks for evaluating such defenses [6].

Current anomaly detection methods for ICS can be divided into two main groups. The first group is based on deep learning models such as LSTMs, Autoencoders, and Transformers, which learn normal operational patterns and detect measurements that deviate from learned distributions. Although these approaches perform well on benchmark datasets, they do not incorporate physical process laws, making them vulnerable

to stealthy attacks that stay within statistical norms [7], [8]. The second group relies on physics-based models, including Kalman Filters and rule-based methods, which encode conservation laws as detection rules. However, these models depend on fixed process parameters obtained from equipment design or offline tuning [9]. In real plants, physical parameters change over time: valve discharge coefficients degrade due to wear, pipe roughness increases because of fouling, and sensor biases slowly drift during long-term operation. This mismatch between assumed models and real system behavior, called the “Reality Gap”, reduces detection accuracy, leading to false alarms under normal variations or missed attacks that mimic outdated models [10], [11]. Thus, the main challenge is to build a detection framework that can continuously estimate the physical state of the system while detecting malicious anomalies.

To address these limitations, this paper proposes the Adaptive Graph Physics-Informed Neural Network (AG-PINN). Our approach treats physical coefficients as learnable parameters that are jointly optimized with a Graph Attention Network, enabling the model to perform real-time System Identification alongside anomaly detection. This creates a self-calibrating digital twin (DT) that tracks equipment degradation automatically. We evaluate AG-PINN on the SWaT and WADI benchmarks against seven state-of-the-art baselines, including a detailed robustness analysis against five categories of stealthy attacks.

The rest of this paper is structured as follows. Section II reviews related work and identifies research gaps. Section III defines the problem. Section IV presents the AG-PINN architecture. Section V reports experimental results, and Section VII concludes the paper.

II. RELATED WORKS

A. Data-Driven Anomaly Detection in ICS

Deep learning has become the dominant approach for multivariate time-series anomaly detection in ICS. Su et al. [12] proposed OmniAnomaly, which combines stochastic recurrent networks with normalizing flows to model complex temporal distributions. Audibert et al. [13] introduced USAD, using adversarial dual-decoder autoencoders for unsupervised detection. Transformer-based models further improved performance: Tuli et al. [14] developed TranAD with adversarial training on a transformer encoder-decoder, while Xu et al. [15] proposed AnomalyTransformer with anomaly-attention to separate prior and series dependencies. Wu et al. [16] proposed TimesNet, which transforms 1D time series into 2D tensors

to capture multi-period patterns. Recently, self-supervised and contrastive learning methods gained interest; Darban et al. [17] proposed CARLA for strong cross-dataset generalization without labeled anomalies. Wang et al. [18] introduced FusionFormer, combining adversarial training with fusion attention to model local and global dependencies. Decomposition-based methods were also explored: Zhang and Luo [19] proposed a multi-scale transformer that separates trend and noise components. Despite these advances, these models only learn statistical patterns and do not use physical process knowledge, making them vulnerable to stealthy FDI attacks that keep normal statistical behavior.

B. Graph-Based Approaches for Sensor Network Modeling

Industrial control systems have a natural graph structure due to physical connections between components, which motivates the use of Graph Neural Networks (GNNs) for modeling inter-sensor relationships. Deng and Hooi [20] proposed GDN, which learns graph structure using embedding similarity and detects anomalies through graph deviation scores. Gao et al. [21] proposed a dynamic graph attention network that updates the adjacency matrix over time to adapt to changing operating conditions in multivariate industrial data. Presekal et al. [22] developed a spatio-temporal graph framework for cyber-physical power systems, showing that encoding physical topology improves detection of advanced attacks exploiting component dependencies. Xu et al. [23] introduced DAN, which combines channel-wise and spatial graph attention. Zhang et al. [24] proposed a spatial-temporal graph learning method with topology-aware convolution to capture both structural and temporal patterns. However, these methods rely only on data correlations to learn graph structure. They do not consider physical meaning of connections, such as mass balance relations between pumps and tanks, which limits detection of attacks that keep statistical correlations but break physical laws.

C. Physics-Informed Methods for Cyber-Physical Security

Classical model-based detection uses state estimation methods such as Extended Kalman Filters (EKF) and Moving Horizon Estimation (MHE) to predict sensor values from process dynamics. Although theoretically solid, these methods strongly depend on accurate system models and lose performance as equipment ages [25]. Physics-Informed Neural Networks (PINNs), which embed differential equations as soft constraints in the loss function, have been used for anomaly detection in cyber-physical systems. François et al. [26] proposed Physics-Informed Graph Neural Networks for attack path prediction, showing that encoding physical relations in graph structure improves threat analysis. Ren et al. [27] developed a physics-informed mitigation approach for DC microgrids under cyber attacks by combining state estimation with attack-aware compensation. DT concepts have also been used; Kadri et al. [28] proposed a physics-aware hybrid estimator for power systems that combines dataset generation and attack simulation. Moon et al. [29] introduced a physics-informed LSTM autoencoder for sensor anomaly detection in DC-DC converters. However, these physics-informed methods assume physical parameters are constant values from equipment datasheets or offline calibration. When parameters

change due to wear, fouling, or sensor drift, physics residuals become unreliable, causing false alarms or missing stealthy attacks that satisfy outdated model constraints.

D. Research Gap and Research Questions

The review shows that each detection paradigm covers only part of robust FDI detection. Data-driven methods capture statistics but ignore physical feasibility. Graph-based methods rely on correlation-based structure instead of real physical topology. Physics-informed methods enforce conservation laws but assume fixed parameters that become outdated over time.

Three main gaps remain:

Gap 1 – Static physics parameters. Current PINN-based detectors do not adapt physical coefficients to equipment aging, causing model mismatch due to wear, fouling, and sensor drift.

Gap 2 – Separate spatial and physical modeling. Graph models ignore governing equations, while physics-based models ignore spatial coupling across plant components.

Gap 3 – Limited adversarial evaluation. Existing methods are rarely tested against physics-aware adversaries that can design attacks satisfying static models.

These gaps lead to the following research questions:

- **RQ1:** Can a model jointly estimate evolving physical parameters and detect anomalies to stay calibrated to plant state?
- **RQ2:** Does combining graph spatial learning with adaptive physics constraints improve FDI detection?
- **RQ3:** How robust is the model against adversaries with knowledge of process dynamics and detector design?

Table I positions AG-PINN relative to the baselines used in this study along five dimensions.

Table I
COMPARISON OF DETECTION APPROACHES ALONG KEY DIMENSIONS

Method	Spatial Graph	Temporal Model	Physics Constraint	Adaptive Params	Stealthy Robust
OmniAnomaly [12]	×	✓	×	×	×
USAD [13]	×	✓	×	×	×
GDN [20]	✓	✓	×	×	×
TranAD [14]	×	✓	×	×	×
AnomalyTransformer [15]	×	✓	×	×	×
TimesNet [16]	×	✓	×	×	×
DCdetector [30]	×	✓	×	×	×
Static PINN	×	×	✓	×	×
EKF / MHE	×	×	✓	×	×
AG-PINN (Ours)	✓	✓	✓	✓	✓

III. PROBLEM STATEMENT

A. The Vulnerability of Data-Driven Detectors

Current anomaly detection frameworks for ICS, such as those evaluated on the SWaT testbed, primarily rely on deep learning architectures to learn temporal correlations from historical data. However, these models lack an inherent understanding of the conservation laws that govern the physical process. A sophisticated adversary can exploit this gap by injecting a stealthy FDI attack vector a_k . If the attack is designed such that the compromised measurement $y_k^a = y_k + a_k$ falls within the statistical manifold of the training data, the detector fails to raise an alarm even when the underlying physical state is impossible.

B. The Reality Gap and Parameter Drift

A fundamental weakness in existing physics-informed detectors is the assumption of a perfect and static physical model. In operational plants such as SWaT, physical parameters change over time through several mechanisms:

- 1) **Hydraulic Wear:** Discharge coefficients (C_d) of valves and pumps degrade gradually due to mechanical erosion and cavitation.
- 2) **Fouling:** Accumulation of mineral deposits and biological growth in pipes alters the effective cross-sectional area and increases friction.
- 3) **Sensor Bias:** Natural drift in Level Indicator Transmitter (LIT) sensors introduces systematic measurement errors that grow over months of operation.

When physics-based checks rely on fixed parameters, they cannot distinguish between a malicious attack and natural system aging, leading to elevated False Positive Rates (FPR). The challenge, therefore, is to develop a model that dynamically reconstructs the plant's physical state while simultaneously detecting genuine anomalies.

IV. PROPOSED METHODOLOGY: AG-PINN

We propose the *Adaptive Graph Physics-Informed Neural Network (AG-PINN)*, which integrates topological spatial awareness with a differentiable physics engine that performs real-time System Identification (SysID). The architecture consists of three tightly coupled components: a Graph Attention encoder for spatial dependencies, a bidirectional LSTM for temporal dynamics, and a Differentiable Physics Layer for physical consistency enforcement.

A. Spatio-Temporal Graph Encoding

The ICS is modeled as a directed graph $\mathcal{G} = (\mathcal{V}, \mathcal{E})$, where $\mathcal{V}$ represents the set of sensors and actuators (51 nodes in SWaT) and $\mathcal{E}$ captures the physical connections between them. We employ a Graph Attention Network (GAT) to learn attention-weighted aggregation of neighbor information. The hidden state $h_i^{(t)}$ for node i is updated by attending over its physical neighbors $\mathcal{N}(i)$:

$$\begin{aligned} e_{ij} &= \text{LeakyReLU}(\vec{a}^T [W h_i \parallel W h_j]), \\ \alpha_{ij} &= \frac{\exp(e_{ij})}{\sum_{k \in \mathcal{N}(i)} \exp(e_{ik})} \end{aligned} \quad (1)$$

where $W \in \mathbb{R}^{F' \times F}$ is a shared linear projection and $\vec{a} \in \mathbb{R}^{2F'}$ is a learnable attention vector, with $\parallel$ denoting feature concatenation. This mechanism helps the model capture causal dependencies between process variables, such as the relation between water level in Tank T101, pump P101 flow rate, and valve MV101 state. The graph structure $\mathcal{E}$ is initialized using the plant P&ID diagram, allowing the model to refine known physical connections instead of learning them from zero. The attention mechanism further captures dynamic operational interactions, including nonlinear pump behavior and pressure transients, which are not explicitly described by the closed-form mass balance in Eq. 2. Ablation results show that removing the GAT module (variant D) decreases stealthy attack recall by 30.8%, even when the Physics Layer remains active.

B. Differentiable Physics Layer (DPL)

The key innovation of AG-PINN is embedding physical coefficients as trainable weights Θ_{phy} within the network rather than treating them as immutable constants. For the SWaT process stage P1, the mass balance equation governing the tank level is:

$$\frac{d\hat{L}}{dt} = \frac{1}{\hat{A}} \left(Q_{in}(t) - \hat{C}_d \cdot u(t) \sqrt{2g\hat{L}(t)} \right) \quad (2)$$

where $\hat{A}$ (m^2 , effective cross-sectional area), $\hat{C}_d$ (dimensionless discharge coefficient), Q_{in} (m^3/s , inflow rate), $u(t) \in [0, 1]$ (normalised valve opening), and $g = 9.81 \text{ m/s}^2$ are the model parameters; $\hat{A}$ and $\hat{C}_d$ are adaptive. The DPL minimizes the residual between the neural network predicted state derivative and the derivative imposed by Eq. 2. During training, gradients are propagated through both network weights and Θ_{phy} , enabling simultaneous learning of process dynamics and calibration of physical coefficients to the current plant condition. During deployment, Θ_{phy} are kept fixed after initial training, while long-term drift is handled by periodic sliding-window recalibration that updates only Θ_{phy} using a 24-hour window of recent normal-operation residuals, without modifying network weights. This structure maintains inference stability while allowing slow tracking of degradation trends.

The learnable physical parameters per process stage include effective tank area ($\hat{A}$), discharge coefficient ($\hat{C}_d$), pipe roughness ($\hat{\epsilon}$), pump efficiency ($\hat{\eta}_p$), valve resistance ($\hat{K}_v$), and sensor bias ($\hat{b}$). To avoid adversarial exploitation, each parameter $\theta_i \in \Theta_{phy}$ is constrained by a maximum variation rate $|\Delta\theta_i/\Delta t| \leq \delta_i^{max}$, where δ_i^{max} is chosen based on the physical degradation time scale of each component (e.g., valve wear evolves over weeks rather than minutes). Anomaly detection is activated when a measured signal change would require violating $|\Delta\theta_i/\Delta t| > \delta_i^{max}$, distinguishing natural aging from adversarial behavior.

C. Joint Optimization and Residual Fusion

AG-PINN is trained using a multi-objective loss function that balances data fidelity and physical consistency:

$$\mathcal{L}_{total} = \underbrace{\frac{1}{N} \sum ||y - \hat{y}||^2}_{\mathcal{L}_{data}} + \lambda \cdot \underbrace{\frac{1}{N} \sum ||\dot{\hat{y}} - \mathcal{F}(\hat{y}, u, \Theta_{phy})||^2}_{\mathcal{L}_{physics}} \quad (3)$$

where N is the batch size, $\dot{\hat{y}}$ represents the predicted state derivative estimated using finite differences, $\mathcal{F}$ is the physics model defined in Eq. 2, and λ balances data fitting and physics consistency. During training, gradients update both the GAT-LSTM parameters and the physical parameter set Θ_{phy} . This joint optimization allows the model to adapt its physical representation to current operating conditions before performing anomaly evaluation.

D. Anomaly Detection Logic

During online inference, the detection score S_t at each timestep combines the statistical reconstruction error and the physical residual:

$$S_t = \alpha \cdot \text{Norm}(e_{stat}) + (1 - \alpha) \cdot \text{Norm}(e_{phys}) \quad (4)$$

where $\alpha = 0.6$ is tuned using the validation set, $\text{Norm}(\cdot)$ denotes min-max normalization computed over a 1-hour rolling window, e_{stat} measures prediction deviation as $\|y_t - \hat{y}_t\|^2$, and e_{phys} measures physics violation as $\|\dot{y}_t - f(y_t, u_t, \Theta_{phys}^*)\|^2$. The final anomaly score S_t is compared with an adaptive threshold τ , obtained from the tail distribution of validation scores using the Peak-Over-Threshold (POT) approach from Extreme Value Theory (EVT), which provides statistical modeling for rare extreme events.

Algorithm 1 AG-PINN: Adaptive Training and Anomaly Detection

Require: SWaT Time-series $X \in \mathbb{R}^{T \times D}$, Graph Topology $\mathcal{G}$, Physics Priors Θ_{phys}^0
Ensure: Trained Model $\mathcal{M}$, Adaptive Parameters Θ_{phys}^* , Anomaly Flags $\mathcal{A}$

```

1: Phase 1: Adaptive Physics Calibration
2: for each epoch  $e \in \{1, \dots, E\}$  do
3:    $\hat{X}_{t+1} \leftarrow \text{GAT-LSTM}(X_{t-k:t}, \mathcal{G})$  ▷ Predict next state
4:    $\mathcal{R}_{phys} \leftarrow \text{Compute Physics Residual}(\hat{X}_{t+1}, U_t, \Theta_{phys}^e)$ 
5:    $\mathcal{L}_{total} \leftarrow \text{MSE}(X_{t+1}, \hat{X}_{t+1}) + \lambda \cdot \|\mathcal{R}_{phys}\|^2$ 
6:    $\nabla \mathcal{L} \rightarrow \text{Update Weights } W \text{ and Physics Params } \Theta_{phys}$ 
7: end for
8: Phase 2: Periodic Recalibration (every 24 h)
9:  $\mathcal{W} \leftarrow$  sliding window of recent normal-operation samples
10:  $\Theta_{phys}^* \leftarrow \arg \min_{\Theta_{phys}} \mathcal{L}_{physics}(\mathcal{W})$  s.t.  $|\Delta \theta_i / \Delta t| \leq \delta_i^{max}$ 
11: Phase 3: Real-time FDI Detection
12: while Online Data Stream  $y_t$  arrives do
13:    $\hat{y}_t \leftarrow \text{Inference}(\mathcal{M}, y_{t-k:t-1})$ 
14:    $e_{stat} \leftarrow \|y_t - \hat{y}_t\|^2$  ▷ Statistical Deviation
15:    $e_{phys} \leftarrow \|\dot{y}_t - f(y_t, u_t, \Theta_{phys}^*)\|^2$  ▷ Physical Violation
16:    $Score_t \leftarrow \alpha \cdot \text{Norm}(e_{stat}) + (1 - \alpha) \cdot \text{Norm}(e_{phys})$ 
17:   if  $Score_t > \tau_{EVT}$  then
18:      $\mathcal{A}_t \leftarrow 1$  ▷ FDI Attack Alert
19:     Log "Physics residual violation at node  $i$ "
20:   else
21:      $\mathcal{A}_t \leftarrow 0$  ▷ Normal Operation
22:   end if
23: end while
    
```

V. EXPERIMENTAL EVALUATION

A. Datasets and Experimental Infrastructure

1) *Primary Dataset: SWaT*: SWaT is a scaled-down water treatment plant at iTrust, SUTD, comprising six stages with 51 sensors and 41 actuators. The dataset covers 11 days: 7 days of normal operation (946,722 samples at 1 Hz) and 4 days under 36 attack scenarios (449,919 samples), ranging from single-point spoofing to complex multi-stage intrusions.

2) *Cross-Validation Dataset: WADI*: WADI, from the same research center, simulates a water distribution network with 123 sensors and actuators across three subsystems. It spans 16 days with 15 attack scenarios designed to evade rule-based detectors, emphasizing hydraulic pressure and pump coordination—making it well-suited for cross-domain transfer evaluation.

3) *Hardware and Software Configuration*: All experiments were executed on a workstation equipped with an Intel Core i9-14900K CPU (24 cores, 3.2 GHz base / 6.0 GHz turbo), 64 GB DDR5-5600 RAM, and an NVIDIA RTX 4070 GPU (12 GB GDDR6X). The software environment consists of Ubuntu 22.04 LTS, PyTorch 2.5.0, CUDA 12.1, and cuDNN 8.9. The Physics Layer computations leverage Intel MKL with AVX-512 vector operations. All code is implemented in Python 3.11 and will be released upon acceptance.

B. Baseline Models and Configuration

We compare AG-PINN against seven methods spanning three detection paradigms.

- **OmniAnomaly (KDD 2019) [12]**: A VAE-based model with stochastic recurrent networks. Latent dimension: 32, RNN hidden size: 128, with planar normalizing flows.
- **USAD (KDD 2020) [13]**: An adversarial autoencoder with dual-decoder architecture. Encoder/decoder layers: [51, 128, 64, 32], trained for 100 epochs with Adam ($lr = 10^{-3}$).
- **GDN (AAAI 2021) [20]**: Graph Deviation Network with learned adjacency matrix. Embedding dimension: 64, top-15 neighbors, sliding window: 5.
- **TranAD (VLDB 2022) [14]**: Transformer-based detector with adversarial training. Attention heads: 4, feed-forward dimension: 256, sequence length: 100.
- **AnomalyTransformer (ICLR 2022) [15]**: Anomaly-Attention mechanism with 3 encoder layers, 8 heads, hidden dimension: 128.
- **TimesNet (ICLR 2023) [16]**: Multi-periodicity backbone using 2D tensor transformation. Top-5 FFT frequencies, Inception kernel sizes: [1, 3, 5].
- **DCdetector (VLDB 2023) [30]**: Dual-attention mechanism with channel-wise and temporal self-attention. Window: 100, layers: 4, hidden dimension: 128.

All baselines were re-implemented using official code repositories and optimized via grid search on a held-out validation set.

1) *AG-PINN Configuration*: The proposed model uses a 3-layer GAT with 8 attention heads per layer and 128 hidden dimensions. The temporal encoder is a 2-layer bidirectional LSTM with 128 hidden units. The Adaptive Physics Layer maintains 6 learnable parameters per process stage. Training was performed for 40 epochs using AdamW ($lr = 10^{-3}$, weight decay $= 10^{-5}$) with batch size 128 and $\lambda = 0.5$.

C. Evaluation Metrics

We report Precision, Recall, F1-Score, Area Under the Precision-Recall Curve (AUPRC), and Time-to-Detection (TTD). All experiments were repeated 10 times with different random seeds. We report mean $\pm$ standard deviation and perform paired t-tests ($p < 0.01$). All models share identical data splits (60% train, 20% validation, 20% test) and preprocessing (z-score normalization per sensor).

D. Overall Performance Comparison

Table II presents the comprehensive results on the SWaT test set.

AG-PINN achieves the highest F1-Score (0.971), surpassing DCdetector by 2.9 percentage points ($p = 0.003$). The precision of 0.978 reflects a very low false positive rate, with rare alarms occurring during pump startup transients that briefly violated steady-state assumptions. Recall of 0.965 indicates strong robustness, with only 12 missed detections in complex multi-stage scenarios. Time-to-Detection of 3.2 seconds—the fastest among all methods—stems from the Physics Layer’s sensitivity to derivative inconsistencies rather than threshold violations. Despite using fewer parameters (245K vs. 512K), AG-PINN outperforms all baselines, demonstrating the effectiveness of physics-informed inductive bias.

Table II
PERFORMANCE COMPARISON ON SWAT DATASET (MEAN $\pm$ STD OVER 10 RUNS)

Model	Precision	Recall	F1-Score	AUPRC	TTD (s)	Latency (ms)	Params (K)
OmniAnomaly [12]	0.874 $\pm$ 0.02	0.792 $\pm$ 0.03	0.831 $\pm$ 0.02	0.847	12.4	3.82	187
USAD [13]	0.901 $\pm$ 0.02	0.825 $\pm$ 0.02	0.861 $\pm$ 0.02	0.878	8.7	2.14	203
GDN [20]	0.932 $\pm$ 0.01	0.811 $\pm$ 0.02	0.867 $\pm$ 0.01	0.884	6.3	2.45	241
TranAD [14]	0.892 $\pm$ 0.02	0.913 $\pm$ 0.01	0.902 $\pm$ 0.01	0.915	7.1	4.12	312
AnomalyTransformer [15]	0.918 $\pm$ 0.01	0.896 $\pm$ 0.02	0.907 $\pm$ 0.01	0.921	5.8	5.67	428
TimesNet [16]	0.945 $\pm$ 0.01	0.887 $\pm$ 0.02	0.915 $\pm$ 0.01	0.924	9.2	6.78	389
DCdetector [30]	0.961 $\pm$ 0.01	0.924 $\pm$ 0.01	0.942 $\pm$ 0.01	0.958	4.5	4.93	512
AG-PINN (Ours)	0.978 $\pm$ 0.01	0.965 $\pm$ 0.01	0.971 $\pm$ 0.01	0.982	3.2	1.15	245

E. Stealthy Attack Detection Analysis

We designed five categories of stealthy attacks to evaluate robustness against sophisticated adversaries. These 26 instances are a subset of the 36 SWaT attack scenarios selected based on their low statistical visibility (reconstruction error below the 2σ bound of the training distribution); the five categories span a structured threat spectrum from operationally realistic vectors (ramp, bias, replay) to worst-case white-box threats (geometric, model inversion), enabling systematic evaluation across adversarial capability levels. Unlike naive attacks that trigger obvious statistical anomalies, these are crafted to remain within normal operational bounds.

Ramp Attack. The attacker injects a linear drift $y_t^{attack} = y_t^{true} + \alpha(t - t_0)$ with $\alpha = 0.001$ mm/s over 30–60 minutes. AG-PINN detects this by comparing the measured rate-of-change with the physics-predicted derivative from Torricelli’s Law.

Bias Injection. A constant offset $\beta \sim \mathcal{N}(0.5, 0.1)$ is added, carefully tuned to stay within 3σ bounds. The Adaptive Physics Layer detects this because the injected bias is inconsistent with the recalibrated sensor bias parameter.

Replay Attack. Previously recorded normal data is replayed during a different operational phase. The GAT captures the spatial inconsistency between sensor readings and actuator commands.

Geometric Attack. An adversary with knowledge of the physical model crafts perturbations that satisfy assumed static physics equations. This fails against AG-PINN because the adversary uses outdated parameters $\Theta_{assumed}$, while AG-PINN has learned the actual evolved parameters Θ_{phy}^* .

Model Inversion Attack. A gray-box adversary uses gradient-based methods to generate adversarial perturbations. Since the attacker cannot simultaneously optimize for neural network evasion and physical law satisfaction (especially with unknown adaptive parameters), the physics residual remains elevated.

Table III reports the detection performance across all five categories.

The results reveal key findings. DCdetector fails against ramp attacks since slow drifts fall within learned temporal variance, whereas AG-PINN’s physics gradient provides an absolute reference independent of historical statistics. Adaptive parameters ensure robustness against geometric attacks even for white-box adversaries, as the evolved parameters remain unpredictable without long-term observation. Perfect recall on model inversion attacks confirms that dual-objective optimization creates a substantially harder attack surface.

F. Cross-Dataset Generalization

To evaluate transferability, AG-PINN trained on SWaT was applied directly to WADI without full retraining. The WADI graph was constructed from its published P&ID, yielding 123 nodes and 187 directed edges across three subsystems. Only the Physics Layer was fine-tuned using 10% of normal-operation data (≈ 1.5 days), simulating a realistic deployment where labeled attack data is unavailable. In transfer mode, AG-PINN achieves an F1-Score of 0.899, outperforming fully retrained baselines and confirming that physics-based inductive bias generalizes well across hydraulic systems. The 2.1% gap between transferred and retrained models suggests that detection relies primarily on physical laws rather than dataset-specific features. Moreover, fine-tuning only the Physics Layer (6 parameters per stage) demands far less data than full retraining, making adaptation to new deployments practical.

G. Ablation Study

We systematically evaluate the contribution of each architectural component through five variants. Variant C (Non-Adaptive GAT without physics recalibration) achieves F1=0.931 and FPR=1.42%, showing that adaptive parameters alone reduce FPR by 94.5% compared to the static model. Adding physics constraints (variant E vs A) improves F1 by 7.6% and lowers FPR by 98%, removing false alarms during normal operating variations. Comparing E and B shows adaptive learning further raises F1 by 4.7% and decreases FPR from 3.85% to 0.08%. The Static-PINN produces false positives under system aging, since valve wear changed the discharge coefficient from 0.62 to 0.58 after 30 days. The GAT module improves F1 by 5.9% over D; attention weights (e.g., 0.87 from *LIT101* to *P101*) correctly capture physical causality. Stealthy attack recall increases from 53.8% (A) to 69.2% (B) and 92.3% (E), confirming that adaptive physics modeling is essential for detecting advanced attacks.

H. System Aging Simulation

Industrial systems degrade continuously. We simulated 90 days of operation by injecting gradual drift into the physical parameters: valve discharge coefficient decreasing linearly ($C_d(t) = 0.62 - 0.001 \cdot t/24$), sensor bias accumulating with noise ($b(t) = b_0 + 0.0005t + \mathcal{N}(0, 0.01)$), and pipe roughness increasing with fouling ($\epsilon(t) = \epsilon_0 \cdot (1 + 0.002\sqrt{t})$).

AG-PINN accurately tracks the degradation curve with only 1.2% average parameter estimation error (Fig. 1) and converges to updated parameters within 24 hours after degradation events. Unlike Static-PINN, whose FPR grows to 12.4% by day 90 due to model drift, AG-PINN keeps FPR

Table III
DETECTION PERFORMANCE ON STEALTHY ATTACK TAXONOMY

Attack Type	Instances	DCdetector		AG-PINN (Ours)		Improvement	
		Recall	TTD (s)	Recall	TTD (s)	Δ Recall	Δ TTD
Ramp Attack	8	0.625	28.4	0.875	15.2	+25.0%	-46.5%
Bias Injection	6	0.833	12.7	0.917	7.3	+8.4%	-42.5%
Replay Attack	5	0.800	9.1	1.000	4.8	+20.0%	-47.3%
Geometric Attack	4	0.500	35.2	0.750	18.9	+25.0%	-46.3%
Model Inversion	3	0.667	22.8	1.000	11.4	+33.3%	-50.0%
Overall	26	0.692	21.6	0.923	11.5	+23.1%	-46.8%

[†]Categories with <5 instances; interpret recall improvements as indicative only.

Table IV
CROSS-DATASET TRANSFER PERFORMANCE (SWAT $\rightarrow$ WADI)

Model	Precision	Recall	F1-Score	AUPRC
GDN (retrained)	0.857	0.743	0.796	0.812
DCdetector (retrained)	0.892	0.814	0.851	0.869
AG-PINN (transferred)	0.921	0.878	0.899	0.913
AG-PINN (retrained)	0.934	0.907	0.920	0.937

Table V
ABLATION STUDY: COMPONENT CONTRIBUTION ANALYSIS

Configuration	F1	FPR (%)	Stealthy Recall	TTD (s)
A: No-Physics	0.895	4.12	0.538	9.7
B: Static-PINN	0.924	3.85	0.692	7.4
C: Non-Adaptive	0.931	1.42	0.731	6.8
D: No-Graph	0.912	2.89	0.615	8.2
E: AG-PINN Full	0.971	0.08	0.923	3.2

below 0.5% over time. This demonstrates that AG-PINN acts as a self-calibrating digital twin, eliminating the need for manual recalibration.

I. Sensitivity Analysis

1) *Physics Weight* λ : We swept $\lambda \in [0, 0.01, 0.1, 0.5, 1.0, 2.0, 5.0, 10.0]$.

Table VI
IMPACT OF PHYSICS WEIGHT λ ON DETECTION PERFORMANCE

λ	Precision	Recall	F1-Score
0.00 (No Physics)	0.892	0.901	0.896
0.01	0.901	0.908	0.904
0.10	0.934	0.927	0.930
0.50 (Selected)	0.978	0.965	0.971
1.00	0.971	0.958	0.964
2.00	0.962	0.947	0.954
5.00	0.943	0.921	0.932
10.00	0.914	0.887	0.900

Table VI reports F1-Score across the full sweep. Small values of λ (< 0.1) produce a purely data-driven detector that misses physics violations, while large values (> 2.0) cause over-regularization: when $\mathcal{L}_{physics}$ dominates, the gradient signal from $\mathcal{L}_{data}$ weakens, reducing the model’s ability to detect non-physical attacks such as replay and bias injection. This is visible in Table VI as degraded recall at $\lambda = 10$ (0.887 vs. 0.965 at $\lambda = 0.5$). Performance stabilizes within $\lambda \in [0.3, 0.7]$, confirming reasonable robustness to this hyper-parameter.

2) *GAT Depth and Training Data Efficiency*: F1-Score improves from 0.927 (1 layer) to 0.971 (3 layers), with diminishing returns and increased latency beyond that. Deeper GATs (e.g., 8 layers) suffer from over-smoothing, making node representations less distinguishable.



Figure 1. Evolution of physical parameters over 90-day system aging. **(Top)** Discharge coefficient ($\hat{C}_d$): AG-PINN (blue) adaptively tracks true degradation (red dashed) from 0.62 to approximately 0.60, while Static-PINN (gray) remains fixed. **(Bottom)** Pipe roughness ($\hat{\epsilon}$): AG-PINN (green) follows the fouling accumulation trend. The adaptive mechanism maintains sub-0.5% FPR throughout.

Regarding data efficiency, AG-PINN trained on only 10% of data reaches an F1-Score of 0.854, comparable to DCdetector at 50% (F1 = 0.903). This gain stems from the physics inductive bias, which improves generalization under limited data—a practical advantage for new deployments with scarce operational history.

J. Computational Efficiency

Table VII
COMPUTATIONAL COST ANALYSIS (PER SAMPLE INFERENCE)

Component	Params	FLOPs (M)	Memory (MB)	Latency (ms)	% Total
GAT (3 layers)	124K	2.34	45	0.42	36.5%
LSTM (2 layers)	89K	1.87	32	0.38	33.0%
Physics Layer	36	0.12	3	0.21	18.3%
Attention Pooling	32K	0.41	8	0.14	12.2%
Total	245K	4.74	88	1.15	100%

As detailed in Table VII, the Physics Layer maintains only 36 scalar learnable coefficients (6 physical parameters $\times$ 6 process stages) and contributes only 18.3% of total latency despite providing the majority of stealthy attack detection capability. Physical equations are solved analytically via vectorized CPU operations (AVX-512), avoiding iterative overhead.

The total memory footprint of 88 MB enables deployment on edge devices such as Siemens S7-1500 Advanced Controllers. Under stress testing with upsampled data, AG-PINN maintains throughput above 700 samples per second even at 1 kHz sampling, meeting real-time constraints for the vast majority of industrial applications.

K. Adversarial Robustness

To evaluate worst-case security, we assume a fully informed adversary with complete knowledge of AG-PINN’s architecture and apply Projected Gradient Descent (PGD) attacks with varying perturbation budgets ϵ .

Table VIII
ADVERSARIAL ROBUSTNESS UNDER WHITE-BOX PGD ATTACKS

ϵ	Clean Recall	Adv. Recall	Robustness	Phys. Violations
0.01	0.965	0.947	98.1%	92.3%
0.05	0.965	0.921	95.4%	88.7%
0.10	0.965	0.884	91.6%	81.2%
0.20	0.965	0.832	86.2%	73.5%

Table VIII summarizes the results. Even under white-box attacks with $\epsilon = 0.05$, AG-PINN retains 95.4% of its clean-data recall. At $\epsilon = 0.01$, 92.3% of adversarial examples still trigger the Physics Layer despite fooling the neural components. The robustness degrades gracefully as ϵ increases, contrasting with brittle detectors that exhibit catastrophic failure at specific thresholds.

L. Comparison with Physics-Only Methods

Table IX
COMPARISON WITH PHYSICS-ONLY DETECTION METHODS. EKF AND MHE ARE APPLIED HERE IN ANOMALY DETECTION MODE VIA RESIDUAL THRESHOLDING ON STATE ESTIMATION ERROR, CONSISTENT WITH [25].

Method	Precision	Recall	F1-Score	Latency (ms)
Extended Kalman Filter	0.843	0.721	0.777	0.52
Moving Horizon Estimation	0.867	0.764	0.812	3.84
AG-PINN (Hybrid)	0.978	0.965	0.971	1.15

Table IX compares AG-PINN against classical physics-only detectors. Physics-only methods suffer from low recall due to their reliance on perfect model accuracy. Unmodeled dynamics such as valve hysteresis, pipe elasticity, and sensor nonlinearity cause frequent false negatives. The EKF’s low precision arises from its Gaussian noise assumption, which poorly captures the heavy-tailed distribution of industrial sensor noise. AG-PINN’s hybrid design compensates for modeling errors through the neural component while retaining the structural advantages of physical constraints.

M. Failure Case Analysis and Limitations

We analyzed 12 false negatives to identify common weaknesses.

Coordinated Multi-Sensor Attacks. Attack #31 manipulated three correlated sensors (*LIT101*, *FIT101*, *P101*) while preserving their physical relationships. The Physics Layer checks local conservation laws but does not enforce global system-level constraints such as total water volume across processing stages.

Sensor Failure Ambiguity. In attack #18, a real hardware failure occurred together with a cyber intrusion. Although the

model detected the anomaly, it could not clearly distinguish between these two causes without a probabilistic reasoning module.

Ultra-Slow Attacks. Attack #27 introduced gradual drift over 12 hours. Although this is shorter than the model’s 24-hour convergence window, the drift was slow enough that the Physics Layer began treating it as normal parameter change before the anomaly score exceeded the detection threshold. The rate-of-change constraint on Θ_{phy} (Section IV) helped partially; attack #27’s drift rate of 0.04 mm/hr was higher than the calibrated valve degradation limit of 0.01 mm/hr, thus triggering a constraint violation signal. However, adversaries matching the degradation rate remain a challenge, and a dual-timescale architecture with separate fast and slow adaptation mechanisms is left for future work.

VI. DISCUSSION

This section revisits the three research questions in Section II-D and summarizes how results answer them, plus remaining limits.

RQ1 (Joint Detection and System Identification). The 90-day aging simulation shows AG-PINN can track physical drift and detect attacks at the same time. The discharge coefficient slowly degraded from 0.62 to about 0.60 with 1.2% mean error, while keeping false positive rate under 0.5%. Static-PINN showed worse stability, reaching 12.4% FPR by day 90 because fixed physics parameters became mismatched with real system state. Ablation results also support this: moving from Static-PINN to full AG-PINN reduced FPR from 3.85% to 0.08%. Learned parameters can also be used as soft indicators of equipment condition such as valve aging or sensor bias.

RQ2 (Graph + Adaptive Physics). Both graph and physics components are necessary. Removing GAT reduced stealthy attack recall from 92.3% to 61.5%, since temporal models cannot capture spatial inconsistency when only one sensor is spoofed. Removing adaptive physics decreased F1-score from 0.971 to 0.895 because data-driven models may miss statistically normal but physically invalid attacks. The full model combines topology-aware attention (e.g., strong dependency weight 0.87 from *LIT101* to *P101*) and physics constraints. Cross-dataset tests on WADI also show good generalization with little tuning.

RQ3 (Robustness to Adversaries). Against stealthy physics-aware attacks, AG-PINN still keeps high recall. For geometric attacks matching static physics, recall remains 75% because adversary parameters differ from learned physical parameters. Under PGD attack with $\epsilon = 0.05$, clean recall stays 95.4% and 88.7% adversarial samples are still detected by physics layer. Attackers must bypass both statistical and physical checks, making attack design harder.

Limitations. Some challenges remain. Multi-sensor coordinated attacks can still bypass local physics checks, suggesting need for global constraints. The model cannot clearly separate hardware failure from cyber attack without probabilistic reasoning. Also, very slow attacks may be absorbed during parameter updates. Finally, the method requires known process topology and equations; in chemically complex or variable-mixture processes where governing equations are difficult to derive accurately, modeling errors may introduce false

alarms—a direction addressed by future Bayesian uncertainty estimation.

VII. CONCLUSIONS

This paper introduces AG-PINN, an Adaptive Graph Physics-Informed Neural Network for detecting stealthy False Data Injection attacks in Industrial Control Systems. By making physical coefficients learnable and optimizing them together with a graph neural architecture, AG-PINN reduces the Reality Gap of fixed physics-based models. Experiments on SWaT and WADI datasets achieved state-of-the-art performance ($F1 = 0.971$), with 23.1% improvement in stealthy attack recall (0.692 to 0.923) and very low false positive rates under 90 days of simulated system aging.

The main idea is that adaptive physics gives a useful inductive bias to detect attacks missed by statistical methods while reducing false alarms during normal system changes. The design keeps neural weights fixed during inference and periodically recalibrates physical parameters using sliding windows, which helps deployment stability. Future work will add global mass-balance constraints, Bayesian uncertainty estimation, and dual-timescale adaptation to better resist adversaries matching natural system degradation patterns.

ACKNOWLEDGEMENTS

This work is financed by the Junta de Extremadura and the European Union (ERDF funds) through the support funds to research groups GR24170.

REFERENCES

- [1] M. M. Aslam, A. Tufail, R. A. A. H. M. Apong, L. C. De Silva, and M. T. Raza, “Scrutinizing security in industrial control systems: An architectural vulnerabilities and communication network perspective,” *IEEE Access*, vol. 12, pp. 67 537–67 573, 2024.
- [2] A. Carlo and K. Obergaell, “Cyber attacks on critical infrastructures and satellite communications,” *International Journal of Critical Infrastructure Protection*, vol. 46, p. 100701, 2024.
- [3] S. S. Jagtap, V. S. Shankar Sriram, K. Kotecha, and S. Vairavasundaram, “Securing industrial control systems from cyber-attacks: A stacked neural-network-based approach,” *IEEE Consumer Electronics Magazine*, vol. 13, no. 1, pp. 30–38, 2024.
- [4] A. Akbarzadeh, L. Erdodi, S. H. Houmb, and T. G. Soltvedt, “Two-stage advanced persistent threat (APT) attack on an IEC 61850 power grid substation,” *International Journal of Information Security*, vol. 23, no. 4, pp. 2739–2758, 2024.
- [5] B. S. Ali, I. Ullah, T. Al Shloul, I. A. Khan *et al.*, “ICS-IDS: Application of big data analysis in AI-based intrusion detection systems to identify cyberattacks in ICS networks,” *Journal of Supercomputing*, vol. 80, no. 6, pp. 7876–7905, 2024.
- [6] R. Canonico, G. Esposito, A. Navarro, S. P. Romano, G. Sperli, and A. Vignali, “An anomaly-based approach for cyber-physical threat detection using network and sensor data,” *Computer Communications*, vol. 234, p. 108087, 2025.
- [7] Z. Lian, P. Shi, and M. Chen, “A survey on cyber-attacks for cyber-physical systems: Modeling, defense, and design,” *IEEE Internet of Things Journal*, vol. 12, 2025.
- [8] H. Ahmad, M. M. Gulzar, G. Mustafa, and S. Habib, “AI-based approach for detecting FDI attacks in load frequency control for centralized multi-area power systems,” *Computers and Electrical Engineering*, vol. 111, 2025.
- [9] Y. Shi, L. Cheng, X. Zhan, and H. Yan, “False data injection attack detection under uncertain parameters in cyber-physical systems,” *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, vol. 55, 2025.
- [10] Y. Lu, M. Zhang, L. Nordström, and Q. Xu, “Digital twin-based cyber-attack detection and mitigation for DC microgrids,” *IEEE Transactions on Smart Grid*, vol. 16, 2025.
- [11] Y. Zhang, C. Du, Z. Chen, Z. Feng, and W. Gui, “Digital twin-based resilient model predictive control for industrial cyber-physical systems,” *IEEE Journal of Emerging and Selected Topics in Industrial Electronics*, 2025.
- [12] Y. Su, Y. Zhao, C. Niu, R. Liu, W. Sun, and D. Pei, “Robust anomaly detection for multivariate time series through stochastic recurrent neural network,” in *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2019, pp. 2828–2837.
- [13] J. Audibert, P. Michiardi, F. Guyard, S. Marti, and M. A. Zuluaga, “Usad: Unsupervised anomaly detection on multivariate time series,” in *Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2020, pp. 3395–3404.
- [14] S. Tuli, G. Casale, and N. R. Jennings, “Tranad: Deep transformer networks for anomaly detection in multivariate time series data,” *Proceedings of the VLDB Endowment*, vol. 15, no. 6, pp. 1201–1214, 2022.
- [15] J. Xu, H. Wu, J. Wang, and M. Long, “Anomaly transformer: Time series anomaly detection with association discrepancy,” in *International Conference on Learning Representations*, 2022.
- [16] H. Wu, T. Hu, Y. Liu, H. Zhou, J. Wang, and M. Long, “Timesnet: Temporal 2d-variation modeling for general time series analysis,” in *International Conference on Learning Representations (ICLR)*, 2023, arXiv:2210.02186.
- [17] Z. Z. Darban, G. I. Webb, S. Pan, C. C. Aggarwal, and M. Salehi, “CARLA: Self-supervised contrastive representation learning for time series anomaly detection,” *Pattern Recognition*, vol. 157, p. 110874, 2025.
- [18] C. Wang, Z. Wang, H. Dong, S. Lauria, W. Liu, and Y. Lu, “Fusionformer: A novel adversarial transformer utilizing fusion attention for multivariate time series anomaly detection,” *IEEE Transactions on Neural Networks and Learning Systems*, 2025.
- [19] W. Zhang and C. Luo, “Decomposition-based multi-scale transformer framework for time series anomaly detection,” *Neural Networks*, vol. 182, p. 106876, 2025.
- [20] A. Deng and B. Hooi, “Graph neural network-based anomaly detection in multivariate time series,” in *Proceedings of the Thirty-Fifth AAAI Conference on Artificial Intelligence (AAAI)*, vol. 35, no. 5, 2021, pp. 4027–4035.
- [21] C. Gao, H. Ma, Q. Pei, and Y. Chen, “Dynamic graph-based graph attention network for anomaly detection in industrial multivariate time series,” *Applied Intelligence*, vol. 55, 2025.
- [22] A. Presekal, A. Stefanov, I. Semertzis, and P. Palensky, “Spatio-temporal advanced persistent threat detection and correlation for cyber-physical power systems,” *IEEE Transactions on Smart Grid*, vol. 16, 2025.
- [23] L. Xu, B. Wang, D. Zhao, and X. Wu, “DAN: Neural network based on dual attention for anomaly detection in ICS,” *Expert Systems with Applications*, vol. 262, 2025.
- [24] J. Zhang, X. Wang, Y. Yang, H. Miao, and S. Yang, “A novel anomaly detection method for multivariate time series based on spatial-temporal graph learning,” *Journal of King Saud University – Computer and Information Sciences*, 2025.
- [25] S. Falas, M. Asprou, C. Konstantinou, and M. K. Michael, “Robust power system state estimation using physics-informed neural networks,” *IEEE Transactions on Industrial Informatics*, vol. 21, 2025.
- [26] M. François, P.-E. Arduin, and M. Merad, “Physics-informed graph neural networks for attack path prediction,” *Journal of Cybersecurity and Privacy*, vol. 5, no. 1, p. 6, 2025.
- [27] W. Ren, J. Peng, Y. Zhou, W. Liu, and H. Jiang, “A physics-informed mitigation method for DC microgrids under cyber attacks,” *Electric Power Systems Research*, 2025.
- [28] B. Kadri, L. Sliman, A. Alsaedi, and G. Abdelkader, “Physics-aware hybrid estimator for dynamic power system dataset generation and cyber attack simulation,” *Energies*, vol. 18, 2025.
- [29] J.-H. Moon, J.-H. Kim, and J.-H. Lee, “Sensor-level anomaly detection in DC–DC buck converters with a physics-informed LSTM: DSP-based validation,” *Sensors*, vol. 25, 2025.
- [30] Y. Yang, C. Zhang, T. Zhou, Q. Wen, and L. Sun, “Dcdetector: Dual attention contrastive representation learning for time series anomaly detection,” *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2023.

De la detección al diagnóstico: interpretación estructural de rupturas ecosistémicas en ciberseguridad

Carlos Mario Braga	Joaquín Sierra	Manuel A. Serrano	Eduardo Fernández-Medina
Grupo Invest. Alarcos	Grupo Invest. GSyA	Grupo Invest. Alarcos	Grupo Invest. GSyA
Univ. de Castilla-La Mancha	Univ. de Castilla-La Mancha	Univ. de Castilla-La Mancha	Univ. de Castilla-La Mancha
Ciudad Real, España	Ciudad Real, España	Ciudad Real, España	Ciudad Real, España
CarlosMario.Braga1@alu.uclm.es	Joaquin.Sierra@uclm.es	Manuel.Serrano@uclm.es	Eduardo.FdezMedina@uclm.es

Resumen—En ciberseguridad, se ha explorado el análisis estructural de ecosistemas digitales como mecanismo no supervisado para anticipar ataques evasivos antes de que se manifiesten anomalías locales. No obstante, la mera detección de una ruptura del equilibrio ecosistémico no es suficiente para discriminar entre adaptaciones funcionales legítimas y perturbaciones ofensivas, lo que introduce ambigüedad en entornos dinámicos y parcialmente observables. Este trabajo aborda esta limitación proponiendo un criterio de diagnóstico estructural que permite interpretar las rupturas ecosistémicas más allá de su mera aparición. La propuesta se basa en el análisis de tres propiedades complementarias de la ruptura, su coherencia multivariable, su persistencia temporal y la estabilidad de su configuración, a partir de las cuales se define una regla de decisión no supervisada, ligera e interpretable, compatible con enfoques previos de detección estructural. La aplicabilidad del criterio se valida empíricamente mediante la ejecución de experimentos sobre un entorno previamente definido en trabajos anteriores, con código y resultados disponibles para su reproducibilidad. Los experimentos muestran que los ataques evasivos tienden a generar rupturas persistentes y coherentes, mientras que los cambios benignos se manifiestan como desviaciones puntuales e inestables. De este modo, el trabajo transforma la detección estructural en un proceso de diagnóstico operativo, reduciendo la ambigüedad inherente a la detección temprana y reforzando su utilidad práctica en entornos reales. Asimismo, dado que el criterio propuesto opera sobre propiedades estructurales de distribuciones empíricas y no sobre los datos en bruto, su aplicación no se limita a un dominio específico, pudiendo extenderse a otros contextos como el análisis de tráfico de red o de registros de eventos.

Index Terms—Ciberseguridad, diagnóstico estructural, detección temprana, ruptura de simetría ecosistémica, sistemas complejos, métodos no supervisados, ataques evasivos

Tipo de contribución: Investigación original

I. INTRODUCCIÓN

Los sistemas actuales de detección de ciberataques se enfrentan a limitaciones crecientes en entornos complejos y dinámicos, donde los adversarios diseñan ataques cada vez más evasivos y miméticos. En estos escenarios, los enfoques basados en reglas, firmas o detección puntual de anomalías resultan insuficientes en ocasiones, ya que los eventos ofensivos pueden reproducir con alta fidelidad el comportamiento legítimo del sistema y eludir los mecanismos de alerta tradicionales [1, 2]. Incluso cuando se emplean mecanismos avanzados de protección y agregación, este tipo de evasión ha sido observado en escenarios reales como el

aprendizaje federado [3], donde ataques de tipo *backdoor semántico* (inserción encubierta de comportamientos maliciosos condicionados al contexto) pueden pasar desapercibidos al no generar anomalías locales evidentes en normas, gradientes o métricas individuales, pese a inducir desviaciones coherentes y persistentes en la estructura global del sistema. Estos resultados ponen de manifiesto que la ausencia de anomalías individuales no implica la ausencia de actividad ofensiva, y que los ataques más sofisticados tienden a manifestarse como perturbaciones sistémicas cuya identificación requiere analizar el comportamiento agregado y su evolución temporal.

Como respuesta a estas limitaciones, se ha iniciado una línea de trabajo que adopta una perspectiva cibernética [4] y estructural de la ciberseguridad, modelando los entornos digitales como ecosistemas en equilibrio dinámico. Desde esta visión, alineada con una concepción sociotécnica de la confiabilidad [5], posteriormente operacionalizada a nivel arquitectónico en entornos distribuidos [6], los ciberataques no se manifiestan necesariamente como anomalías locales, sino como perturbaciones que alteran la estructura estadística global del sistema. En este contexto, la detección de rupturas de simetría ecosistémica, entendida como la pérdida de equilibrio entre las dimensiones estructurales del ecosistema, ha demostrado su capacidad para anticipar ataques evasivos tanto en escenarios de detección de intrusiones como en aprendizaje federado, incluso bajo condiciones de visibilidad limitada o agregación segura [3, 7]. Esta noción, introducida previamente como hipótesis fundacional, se consolida en este artículo como base operativa del diagnóstico estructural.

No obstante, los propios resultados obtenidos en esta línea de trabajo manifiestan una limitación relevante, ya que la existencia de una ruptura del equilibrio estadístico no implica necesariamente la presencia de actividad ofensiva. La evolución normal del sistema, los cambios operativos legítimos o los procesos de adaptación funcional pueden generar desviaciones transitorias respecto a una distribución de referencia sin que exista un ataque, lo que introduce una ambigüedad que dificulta discriminar entre perturbaciones benignas y perturbaciones maliciosas cuando ambas se manifiestan como alteraciones del equilibrio ecosistémico.

Este trabajo aborda explícitamente este problema abierto mediante un criterio de diagnóstico estructural que permite distinguir adaptaciones legítimas del sistema frente a pertur-

baciones ofensivas. A diferencia de los enfoques centrados en la detección, la propuesta se orienta al diagnóstico, analizando propiedades medibles de las rupturas ecosistémicas más allá de su mera aparición. En particular, se define un criterio basado en la coherencia multivariable, la persistencia temporal y la estabilidad de la configuración, propiedades que caracterizan los ataques evasivos como fenómenos estructurales consistentes y sostenidos.

Las principales aportaciones de este trabajo pueden resumirse como sigue:

- Sobre la base de enfoques anteriores de detección estructural temprana, se introduce un criterio de diagnóstico que permite interpretar las rupturas ecosistémicas en función de su forma, duración y coherencia, y así distinguir explícitamente entre perturbaciones ofensivas y adaptaciones funcionales legítimas, incluso cuando ambas alteran el equilibrio estadístico del sistema.
- Se ilustra la aplicabilidad del criterio mediante la ejecución de experimentos sobre un entorno previamente utilizado en trabajos anteriores, permitiendo reinterpretar los resultados obtenidos desde un punto de vista diagnóstico.

Esta extensión no altera las propiedades operativas del enfoque original, manteniendo un carácter no supervisado, ligero y basado en métricas interpretables, sin requerir etiquetas, reentrenamiento ni acceso a datos sensibles adicionales, lo que facilita su integración práctica en entornos reales.

El resto del artículo se organiza del siguiente modo. En la Sección II se revisan los fundamentos conceptuales de la detección estructural ecosistémica y sus limitaciones actuales. La Sección III introduce una tipología de rupturas estructurales que permite contextualizar el criterio propuesto. En la Sección IV se presenta el criterio de diagnóstico estructural, ilustrando la Sección V su aplicación a partir de resultados experimentales previos. La Sección VI discute las implicaciones, limitaciones y alcance del enfoque propuesto, y finalmente, la Sección VII recoge las conclusiones y líneas de trabajo futuro.

II. FUNDAMENTOS DE LA DETECCIÓN ESTRUCTURAL ECOSISTÉMICA

Los enfoques clásicos de detección en ciberseguridad se han basado tradicionalmente en el análisis puntual de eventos individuales, ya sea mediante reglas, firmas o modelos de detección de anomalías entrenados para identificar desviaciones locales respecto a un comportamiento esperado. Aunque estas técnicas han resultado eficaces frente a ataques conocidos, presentan limitaciones en entornos dinámicos y frente a ataques evasivos que mimetizan el comportamiento legítimo del sistema, donde la ausencia de anomalías locales no implica necesariamente la ausencia de actividad ofensiva [1, 2].

Como alternativa a esta visión puntual, en este trabajo se adopta una perspectiva estructural que modela los entornos digitales como ecosistemas complejos en equilibrio dinámico. Esta propuesta se inspira en la cibernética clásica, donde la estabilidad no se define como ausencia de cambio, sino como la capacidad del sistema para mantener su coherencia operativa mediante mecanismos de retroalimentación [4]. Desde esta perspectiva, la ciberseguridad puede interpretarse como la capacidad del ecosistema digital para preservar dicho equilibrio

frente a presiones adversarias, en línea con marcos actuales que conciben la seguridad como una propiedad adaptativa y resiliente del sistema [8].

Esta visión puede extenderse además a una dimensión sociotécnica, en la que la estabilidad del ecosistema emerge de la interacción entre factores técnicos y sociales. En este contexto, la confiabilidad y la resiliencia dejan de entenderse como atributos aislados de componentes individuales y pasan a concebirse como propiedades sistémicas que dependen de la coadaptación entre tecnología, procesos y estructuras organizativas [5].

Bajo este marco, la detección estructural no se centra en identificar eventos atípicos de forma aislada, sino en analizar cambios en la forma global del ecosistema. El comportamiento operativo del sistema puede representarse como una distribución empírica multivariante de eventos observables, cuya evolución temporal permite capturar alteraciones estructurales del estado del sistema [9]. Por ejemplo, en un sistema de red, aunque cada paquete individual parezca legítimo, una modificación coordinada en la proporción de ciertos tipos de tráfico puede alterar la distribución global sin generar anomalías locales evidentes. Medidas como la divergencia de Jensen-Shannon o la distancia de Wasserstein permiten cuantificar estos desplazamientos entre distribuciones empíricas sin requerir entrenamiento supervisado ni la definición previa de patrones específicos [10].

Este enfoque ha mostrado ser especialmente adecuado en escenarios donde la visibilidad local es limitada o manipulable, como en la detección de intrusiones con tráfico mimético [7] o en el aprendizaje federado bajo agregación segura [3], donde los ataques pueden inducir desplazamientos estructurales sin manifestarse como anomalías individuales.

No obstante, la experiencia acumulada en estos escenarios [3, 7] muestra que la detección de una ruptura estructural constituye una condición necesaria, pero no suficiente, para identificar actividad ofensiva. En sistemas reales, la evolución legítima del ecosistema puede generar desviaciones transitorias respecto a una distribución de referencia, por ejemplo tras una actualización de software, un cambio de configuración o una variación estacional en la carga de trabajo, que a nivel de ruptura resultan difíciles de distinguir de las inducidas por ataques. Esta ambigüedad pone de manifiesto la necesidad de avanzar desde una lógica puramente detectiva hacia un enfoque diagnóstico capaz de caracterizar cómo se manifiestan las rupturas en términos de su extensión en el espacio de observables, su persistencia temporal y la estabilidad de los patrones que generan. Sobre esta base se construye la tipología de rupturas estructurales presentada en la siguiente sección, fundamento del criterio de diagnóstico propuesto.

III. TIPOS DE RUPTURAS ESTRUCTURALES

Como se ha establecido en la sección anterior, la detección de una ruptura del equilibrio estadístico es una condición necesaria, pero no suficiente, para identificar actividad ofensiva en ecosistemas digitales complejos. A partir de esta observación, se introduce en esta sección una tipología de rupturas estructurales como primera aportación conceptual del presente trabajo, cuyo objetivo es contextualizar las señales de detección temprana y avanzar hacia el diagnóstico operativo.

La tipología propuesta no introduce nuevas magnitudes cuantitativas, sino que organiza conceptualmente las rupturas observadas en función de cómo se manifiestan en el ecosistema. En particular, la clasificación se basa en tres propiedades estructurales relevantes en este marco, la coherencia de la ruptura entre múltiples dimensiones del sistema, su persistencia temporal y la estabilidad de los patrones que genera. Estas propiedades permiten diferenciar entre desviaciones compatibles con la evolución normal del sistema y alteraciones estructurales consistentes inducidas por actividad adversaria.

Un primer tipo lo constituyen las rupturas puntuales, que se manifiestan como desviaciones aisladas en una o pocas dimensiones o medidas estructurales, generalmente limitadas a un único instante temporal. Este tipo de ruptura es compatible con ruido estadístico, fluctuaciones naturales del sistema o cambios operativos de corta duración. Desde un punto de vista estructural, las rupturas puntuales presentan baja coherencia multivariable, ausencia de persistencia temporal y configuraciones inestables, por lo que no constituyen evidencia suficiente de actividad ofensiva.

Un segundo tipo corresponde a las rupturas persistentes, en las que la desviación estructural se mantiene durante múltiples instantes temporales, superando la variabilidad esperable bajo condiciones benignas. Estas rupturas pueden deberse tanto a perturbaciones ofensivas como a procesos de adaptación funcional más profundos del sistema, como cambios en la carga de trabajo, reconfiguraciones prolongadas o evoluciones legítimas del entorno operativo. Aunque la persistencia temporal refuerza la relevancia de la ruptura, por sí sola no permite discriminar de forma concluyente su naturaleza.

Finalmente, se identifican las rupturas coherentes y persistentes, caracterizadas por afectar de manera simultánea a múltiples dimensiones del ecosistema y mantener un patrón estable a lo largo del tiempo. Este tipo de ruptura refleja una alteración estructural consistente, en la que los mismos estadísticos estructurales exceden sus umbrales de forma recurrente, configurando una firma característica de perturbaciones ofensivas diseñadas para provocar desviaciones sostenidas en el comportamiento global, como ocurre en ataques evasivos o campañas progresivas.

Esta clasificación permite reinterpretar las señales de ruptura no como alertas binarias, sino como manifestaciones de distintos regímenes estructurales del ecosistema. Aunque conceptualmente se apoya en tres propiedades, su representación inicial puede realizarse de forma bidimensional. En particular, para ventanas temporales unitarias ($t = 1$), la persistencia temporal coincide con la densidad de ruptura, y la estabilidad de la configuración no está aún definida al no existir una referencia temporal previa. En este régimen inicial, el espacio estructural relevante es efectivamente bidimensional, lo que permite una caracterización intuitiva de los distintos tipos de ruptura, como se ilustra conceptualmente en la Figura 1.

Mientras que las rupturas puntuales y algunas rupturas persistentes pueden ser compatibles con la evolución normal del sistema, aquellas que presentan coherencia y persistencia simultáneas constituyen indicios más sólidos de actividad maliciosa. Esta tipología proporciona así un marco interpretativo para analizar las rupturas ecosistémicas en función de su forma y comportamiento temporal. En escenarios con datos




Figura 1. Plano conceptual bidimensional que organiza los tipos de rupturas estructurales según su coherencia multivariable y su persistencia temporal.

limitados o alta variabilidad, estas propiedades pueden mostrar mayor inestabilidad y afectar a la robustez del diagnóstico. Asimismo, estrategias adversarias orientadas a reducir la coherencia o estabilidad estructural podrían dificultar su detección, aunque a costa de limitar la efectividad de la perturbación.

IV. CRITERIO DE DIAGNÓSTICO ESTRUCTURAL

A partir de la tipología de rupturas estructurales introducida en la sección anterior, en esta sección se presenta un criterio de diagnóstico estructural que permite operacionalizar dicha clasificación en entornos reales. El objetivo no es detectar nuevas rupturas, sino interpretar las ya observadas para discriminar entre desviaciones transitorias asociadas a la evolución normal del sistema y perturbaciones estructurales consistentes indicativas de actividad ofensiva. Para ello, se formalizan las propiedades de coherencia multivariable, persistencia temporal y estabilidad del patrón de ruptura mediante métricas estructurales agregadas, y se define una regla de decisión no supervisada adecuada para su despliegue operativo.

Sea un ecosistema digital monitorizado mediante un conjunto de estadísticos estructurales $\mathcal{D} = \{D_1, D_2, \dots, D_m\}$, donde cada estadístico cuantifica la desviación del estado actual del sistema respecto a una distribución de referencia legítima P_0 , construida a partir de comportamiento benigno histórico. Para cada estadístico D_i se define un umbral empírico τ_i , estimado a partir de datos benignos.

A partir de estos estadísticos se construye, para cada instante temporal t , un vector binario de ruptura ecosistémica. En particular, se define:

$$R_i(t) = \begin{cases} 1 & \text{si } D_i(t) > \tau_i, \\ 0 & \text{en otro caso} \end{cases}$$

$$\mathbf{R}(t) = (R_1(t), R_2(t), \dots, R_m(t))$$

Este vector representa el estado estructural observado del ecosistema en el instante t , codificando qué dimensiones del sistema han experimentado una ruptura significativa.

Sobre esta representación se definen tres propiedades diagnósticas que permiten operacionalizar la tipología de rupturas estructurales introducida en la sección anterior.

En primer lugar, se introduce la densidad de ruptura, que mide la coherencia multivariable de la perturbación como

la proporción de métricas que superan simultáneamente su umbral:

$$\delta(t) = \frac{1}{m} \sum_{i=1}^m R_i(t)$$

Por construcción, $\delta(t)$ toma valores en el intervalo $[0, 1]$, donde valores cercanos a cero indican rupturas aisladas que afectan a pocos estadísticos estructurales, compatibles con ruido estadístico o variabilidad funcional, mientras que valores cercanos a uno reflejan una alteración altamente coherente que impacta de forma simultánea a múltiples dimensiones del espacio estructural. Este comportamiento constituye un indicio más sólido de perturbación sistémica.

En segundo lugar, se considera la persistencia de la ruptura. Mientras que las adaptaciones legítimas suelen manifestarse como desviaciones puntuales, las perturbaciones ofensivas tienden a mantener su efecto a lo largo del tiempo. Esta propiedad se cuantifica mediante la persistencia media de la densidad de ruptura sobre una ventana temporal de tamaño T :

$$\pi(t) = \frac{1}{T} \sum_{k=t-T+1}^t \delta(k)$$

Por construcción, $\pi(t)$ toma valores en el intervalo $[0, 1]$, donde valores bajos indican rupturas transitorias compatibles con fluctuaciones benignas, mientras que valores elevados reflejan alteraciones estructurales sostenidas en el tiempo, reforzando su interpretación como fenómeno sistémico. La elección del tamaño de la ventana T depende del contexto operativo y del riesgo asociado a la latencia en la toma de decisiones. En sistemas donde la respuesta puede diferirse sin consecuencias inmediatas, T puede tomar valores mayores para aumentar la robustez frente al ruido y reducir falsos positivos. En escenarios como el aprendizaje federado, donde la agregación de actualizaciones maliciosas puede comprometer el modelo global de forma irreversible, resulta crítico considerar el impacto de la latencia en la decisión. En el caso más conservador, esto puede implicar emplear ventanas temporales pequeñas, e incluso $T = 1$, para evaluar de forma inmediata cada actualización antes de su agregación. No obstante, este criterio también permite escenarios intermedios, en los que las actualizaciones que presentan patrones inestables pueden ser temporalmente retenidas o priorizadas para evaluación adicional, permitiendo acumular evidencia temporal antes de su incorporación al modelo global.

En el caso límite $T = 1$, la persistencia temporal coincide con la densidad de ruptura instantánea, es decir, $\pi(t) = \delta(t)$, ya que no existe referencia temporal previa. En este escenario, no resulta necesario calcular explícitamente la persistencia temporal, ya que la evaluación se realiza de forma inmediata sobre la coherencia multivariable observada en cada instante.

Finalmente, se evalúa la estabilidad de la configuración de ruptura, con el objetivo de analizar hasta qué punto los mismos estadísticos estructurales resultan afectados de forma recurrente. Mientras que la densidad de ruptura cuantifica cuántos estadísticos exceden simultáneamente su comportamiento de referencia y la persistencia temporal captura la duración de dicha alteración, la estabilidad del patrón permite distinguir

entre rupturas estructurales consistentes y configuraciones inestables asociadas a ruido o adaptación funcional legítima.

La estabilidad del patrón se define inicialmente de forma instantánea, a partir de la similitud entre los vectores binarios de ruptura $\mathbf{R}(t)$ observados en instantes consecutivos. En particular, se define una medida de estabilidad instantánea $S(t)$ como el grado de solapamiento entre los vectores $\mathbf{R}(t)$ y $\mathbf{R}(t-1)$:

$$S(t) = \frac{\sum_{i=1}^m \mathbb{I}(R_i(t) = 1 \wedge R_i(t-1) = 1)}{\sum_{i=1}^m \mathbb{I}(R_i(t) = 1 \vee R_i(t-1) = 1)}$$

donde $\mathbb{I}(\cdot)$ es la función indicadora o característica. Por construcción, $S(t)$ toma valores en el intervalo $[0, 1]$, donde valores elevados indican que los mismos estadísticos estructurales superan sus umbrales de forma recurrente, configurando una firma estructural estable, mientras que valores bajos reflejan patrones cambiantes.

De forma análoga a la persistencia temporal, la estabilidad del patrón puede agregarse a lo largo del tiempo mediante una ventana de tamaño T , calculando la estabilidad media de la configuración de ruptura en dicha ventana. La elección de T sigue los mismos criterios operativos discutidos previamente, adaptándose al dominio de aplicación y al riesgo asociado a la latencia en la toma de decisiones. En escenarios donde la evaluación debe realizarse de forma inmediata, la estabilidad se evalúa únicamente de manera instantánea entre instantes consecutivos utilizando $S(t)$.

Una estabilidad elevada en la configuración de ruptura, especialmente cuando se combina con alta densidad y persistencia, constituye un indicio sólido de perturbación estructural consistente, característica de ataques evasivos. Esta hipótesis ya había sido observada empíricamente en trabajos previos [7], donde ciertas rupturas ofensivas mostraban activaciones recurrentes en los mismos estadísticos estructurales. El presente trabajo formaliza esa observación mediante la métrica $S(t)$, que cuantifica la estabilidad del patrón de ruptura y dota al diagnóstico de mayor sensibilidad y trazabilidad. En este marco, una firma estructural estable se manifiesta como la reiteración de rupturas en los mismos componentes del espacio estructural a lo largo del tiempo, como se evidenció en escenarios de aprendizaje federado [3], donde determinadas proyecciones de la actualización local superaban sistemáticamente sus umbrales en presencia de ataques backdoor, a diferencia de los casos benignos, en los que tales activaciones eran esporádicas o inestables.

A partir de estas propiedades se define una regla de decisión estructural no supervisada que puede describirse operativamente en los siguientes pasos: (i) calcular la densidad de ruptura $\delta(t)$ a partir del vector de ruptura $\mathbf{R}(t)$; (ii) estimar la persistencia temporal $\pi(t)$ sobre una ventana de tamaño T ; (iii) evaluar la estabilidad de la configuración de ruptura mediante $S(t)$; y (iv) comparar estas magnitudes con sus valores de referencia establecidos a partir del comportamiento benigno del sistema para emitir una decisión diagnóstica. Esta secuencia permite discriminar rupturas estructurales persistentes y coherentes, típicas de ataques evasivos, frente a desviaciones transitorias asociadas a la evolución normal del sistema, siguiendo el proceso completo de diagnóstico estructural ilustrado en la Figura 2.




Figura 2. Proceso completo de diagnóstico estructural basado en rupturas estructurales. El proceso integra métricas estructurales, comparación con umbrales de referencia y evaluación de densidad, persistencia temporal y estabilidad del patrón para producir una decisión diagnóstica.

De este modo, la ruptura ecosistémica deja de interpretarse como una señal binaria de alarma y pasa a integrarse en un proceso de diagnóstico estructural alineado con una visión cibernética del sistema, lo que facilita su aplicación operativa en entornos reales.

V. ILUSTRACIÓN EXPERIMENTAL

Esta sección ilustra empíricamente la aplicabilidad del criterio de diagnóstico estructural propuesto, mostrando su capacidad para distinguir perturbaciones ofensivas de adaptaciones funcionales legítimas en el contexto de aprendizaje federado con agregación segura. Para ello, se reutiliza y ejecuta un entorno experimental previamente definido en trabajos anteriores, concretamente el escenario canónico de ataques backdoor introducido por Bagdasaryan et al. [11], que había sido empleado para instrumentar un detector estructural basado en distancias estadísticas orientado a la detección temprana de desviaciones maliciosas bajo visibilidad local limitada [3].

En este estudio, dicho entorno se ejecuta nuevamente con el objetivo de validar empíricamente el enfoque de diagnóstico estructural propuesto, incorporando análisis no considerados en la evaluación original, y permitiendo analizar explícitamente una limitación inherente a los enfoques basados únicamente en umbrales, concretamente la dificultad para discriminar rupturas ofensivas de desviaciones benignas cuando ambas exceden sus valores de referencia. La reproducibilidad del experimento se garantiza mediante la disponibilidad pública del código y los datos empleados (https://github.com/GSYAtools/Backdoor_attacks_FL), incluyendo los scripts utilizados para la ejecución de los experimentos y el cálculo de las métricas diagnósticas.

El sistema experimental corresponde a una federación en la que un servidor central coordina múltiples clientes que entrenan localmente un modelo sobre CIFAR-10, un conjunto de datos de clasificación de imágenes compuesto por 60,000 muestras de tamaño 32×32 distribuidas en diez clases. En cada ronda, cada cliente genera una actualización local $\mathbf{u}^{(t)}$ que no se transmite en bruto, sino que se resume mediante

once proyecciones estadísticas, la norma ℓ_2 y diez proyecciones gaussianas fijas. Esta reducción preserva la privacidad del vector original y disminuye la dimensionalidad, manteniendo información estructural relevante. Cuando un cliente introduce un ataque backdoor, la actualización resultante incorpora una perturbación sistemática en determinadas direcciones del espacio de parámetros, lo que altera la distribución de las proyecciones y provoca un incremento de las distancias estadísticas respecto a la distribución de referencia benigna.

Las once dimensiones obtenidas constituyen el espacio estructural base. Sobre cada una se calculan dos distancias estadísticas univariantes, Energy [12] y Wasserstein [13], entre la observación actual y una distribución de referencia T_0 construida a partir de 50 actualizaciones benignas previas, dando lugar a 22 estadísticos estructurales $D = \{D_1, \dots, D_{22}\}$. Para cada estadístico, T_0 define un rango de variación esperada mediante muestreo bootstrap y cálculo del percentil 99, lo que permite contrastar el valor observado con un umbral empírico calibrado. La superación de dicho umbral en un estadístico D_i indica ruptura, codificada como $R_i(t) = 1$. El vector binario resultante $R(t) \in \{0, 1\}^{22}$ recoge la estructura de ruptura ecosistémica del cliente en la ronda t .

El análisis se apoya en tres escenarios generados previamente en el estudio de detección temprana [3], correspondientes a un cliente benigno entrenando con datos legítimos (T1), un cliente atacante introduciendo un backdoor con escalado alto $\gamma = 100$ (T2), y una variante sigilosa del mismo ataque con escalado reducido $\gamma = 20$ (T3). Cada escenario consta de cinco ejecuciones, equivalentes a cinco rondas locales consecutivas. Las distancias estadísticas obtenidas por dimensión, junto con los umbrales calibrados mediante remuestreo bootstrap sobre actualizaciones benignas, permiten construir los vectores binarios $R(t)$ descritos anteriormente. A partir de ellos se analiza la evolución temporal de las métricas estructurales, que incluyen la densidad de ruptura $\delta(t)$, la persistencia media $\pi(t)$ y la estabilidad del patrón $S(t)$, no definida en la primera observación, al necesitar una referencia de tiempo anterior.

Las métricas estructurales $\delta(t)$, $\pi(t)$ y $S(t)$ se interpretan mediante umbrales diagnósticos independientes de los umbrales de ruptura por dimensión. Mientras estos últimos determinan si un estadístico individual excede su rango benigno, los umbrales diagnósticos se aplican al comportamiento agregado del sistema. Se fijan empíricamente como el percentil 95 de los valores observados en el escenario benigno, estableciendo un límite superior de variación legítima. Los valores obtenidos son $\tau_\delta = 0.164$, $\tau_\pi = 0.067$ y $\tau_S = 0.425$. El diagnóstico ofensivo se activa cuando las tres métricas superan simultáneamente sus respectivos umbrales, o cuando lo hacen $\delta(t)$ y $\pi(t)$ en la primera observación, donde $S(t)$ no está definida.

Este procedimiento de calibración mediante percentiles diagnósticos ya fue validado en trabajos previos [3, 7], donde demostró una alta estabilidad y sensibilidad temprana en escenarios de aprendizaje federado o de detección genérica de anomalías. Su incorporación aquí consolida la continuidad metodológica de la vigilancia estructural y refuerza la interpretabilidad operativa del diagnóstico.

Los resultados se presentan en la Figura 3. En el escenario

benigno (T1), las métricas estructurales se mantienen bajas y dispersas, sin activar la regla diagnóstica en ningún instante. Por el contrario, en el escenario ofensivo fuerte (T2) se observan rupturas densas, persistentes y estables desde las primeras rondas; por ejemplo, en la ronda $t = 2$ la densidad de ruptura $\delta(t)$ supera claramente su umbral, la persistencia media $\pi(t)$ confirma que la activación no es puntual y la estabilidad $S(t)$ refleja la recurrencia en las mismas dimensiones estructurales, configurando un patrón característico de perturbación ofensiva consistente. En el escenario sigiloso (T3), aunque los valores son más moderados, el umbral estructural se supera de forma consistente a partir de $t = 2$. En ambos casos ofensivos, el diagnóstico se activa sin falsos positivos.

Estos resultados refuerzan el valor del criterio propuesto no solo como mecanismo de detección temprana, sino como herramienta de interpretación estructural. Mientras que las métricas $\delta(t)$ y $\pi(t)$ pueden presentar excedencias aisladas también en escenarios benignos, su combinación con una alta estabilidad del patrón $S(t)$ permite distinguir con mayor precisión entre desviaciones funcionales transitorias y perturbaciones ofensivas sostenidas. Esta lectura multivariable de la evidencia estructural ofrece una base más robusta para la toma de decisiones, y convierte las señales de ruptura en indicios interpretables dentro del comportamiento global del sistema.

La Figura 4 muestra la distribución de los puntos $(\delta(t), \pi(t), S(t))$ en el espacio estructural. Se aprecia un desplazamiento progresivo entre los distintos tipos. Los puntos benignos se sitúan en regiones de baja ruptura y baja coherencia, mientras que los ofensivos tienden a ubicarse en áreas con valores más altos en las tres dimensiones. El tipo intermedio ocupa una posición de transición, lo que sugiere la presencia de un gradiente estructural en lugar de una separación binaria estricta.

Estos resultados muestran que el marco de diagnóstico estructural permite reinterpretar señales de detección temprana como evidencia multivariable de actividad ofensiva. Al incorporar coherencia, persistencia y estabilidad, el enfoque reduce la ambigüedad asociada a fluctuaciones locales y refuerza la interpretabilidad de las alertas, sin necesidad de supervisión, etiquetas, ni visibilidad global del sistema.

De forma complementaria, trabajos recientes han documentado ejemplos de rupturas estructurales en otros dominios, como el análisis de tráfico de red mimético [7]. En esos escenarios, se observaron desviaciones sistemáticas en medidas estadísticas como Jensen–Shannon y Wasserstein, incluso en ausencia de señales locales, lo que sugiere que el tipo de comportamiento que aquí se formaliza como diagnóstico ya se manifestaba en otros contextos operativos. Estas observaciones empíricas contribuyeron a motivar la generalización del enfoque actual, reforzando su aplicabilidad más allá del caso específico del aprendizaje federado y ampliando sus capacidades desde la detección de ruptura ecosistémica al diagnóstico estructural de dicha ruptura.

VI. DISCUSIÓN

El criterio de diagnóstico estructural propuesto en este trabajo introduce un cambio de enfoque respecto a los mecanismos de detección temprana en ciberseguridad. En lugar de interpretar la ruptura del equilibrio ecosistémico como una




Figura 3. Evolución de las métricas estructurales $\delta(t)$, $\pi(t)$ y $S(t)$ por escenario. Las líneas horizontales marcan los umbrales diagnósticos calculados como percentiles 95 sobre el escenario benigno. La superación de los tres valores activa el diagnóstico ofensivo.

señal binaria de alarma, el planteamiento adopta una perspectiva diagnóstica que analiza las propiedades estructurales de dicha ruptura para inferir su naturaleza. Esta distinción resulta especialmente relevante en entornos dinámicos, donde la evolución legítima del sistema puede generar desviaciones estructurales sin que exista actividad ofensiva, y donde la detección basada exclusivamente en umbrales locales tiende a producir ambigüedad o falsos positivos. En este contexto, conviene subrayar que el objetivo del diagnóstico no es garantizar la ausencia universal de falsos positivos, sino evitar la activación ante variaciones compatibles con el régimen benigno representado por la distribución de referencia, requi-




Figura 4. Trayectorias estructurales en el espacio (δ, π, S) .

riendo para ello evidencia estructural coherente, persistente y estable.

Desde un punto de vista metodológico, una de las principales ventajas del enfoque es su carácter no supervisado y su independencia tanto del dominio como de datos etiquetados. El criterio se apoya exclusivamente en métricas estructurales agregadas y en valores de referencia derivados del comportamiento benigno del sistema, lo que permite su aplicación en escenarios tan diversos como la detección de intrusiones, el aprendizaje federado o ecosistemas digitales distribuidos, si bien su comportamiento depende de la calidad y representatividad de dicha referencia. Esta característica resulta clave en contextos con visibilidad limitada o control parcial de la información, donde los enfoques supervisados o basados en perfiles de ataque presentan dificultades prácticas de despliegue y mantenimiento. Más allá de su eficacia como detector de actividad ofensiva, el enfoque propuesto contribuye a sostener la coherencia estructural del ecosistema digital, alineándose con principios de confiabilidad sistémica previamente definidos [5]. Al evaluar dimensiones como la coherencia multivariable, la persistencia temporal y la estabilidad del patrón, el diagnóstico proporciona una capa de observación estructural continua que permite identificar desequilibrios operativos de forma anticipada, incluso cuando no se manifiestan como anomalías individuales. Esta capacidad de observación agregada refuerza la resiliencia funcional del sistema y consolida la propuesta como componente verificable dentro de una estrategia de gobernanza técnica adaptativa.

Otro aspecto diferencial del enfoque es su interpretabilidad. La descomposición del diagnóstico en términos de coherencia multivariable, persistencia temporal y estabilidad del patrón de ruptura proporciona explicaciones claras sobre por qué una perturbación se considera ofensiva o compatible con la evolución normal del sistema. Esta capacidad explicativa facilita la integración del criterio en procesos operativos de ciberseguridad, donde las decisiones automáticas suelen requerir supervisión humana, auditoría posterior o justificación frente a marcos regulatorios y organizativos.

Desde el punto de vista operativo, el diagnóstico estructural puede integrarse como una capa complementaria en arquitecturas

de ciberseguridad existentes. En sistemas de detección de intrusos (IDS) o plataformas SIEM, las métricas estructurales pueden actuar como señales tempranas de riesgo ecosistémico, complementando reglas locales con una visión agregada del sistema. En entornos de aprendizaje federado, el diagnóstico puede desplegarse en la fase previa a la agregación, evaluando cada actualización local mediante criterios estructurales antes de permitir su incorporación al modelo global. Esta integración es especialmente valiosa frente a ataques evasivos, que tienden a eludir los detectores convencionales al permanecer dentro de los márgenes normales de cada dimensión individual.

El planteamiento presenta, no obstante, ciertas limitaciones. En primer lugar, la eficacia del diagnóstico depende de la calidad y representatividad de la distribución de referencia utilizada para caracterizar el comportamiento benigno, así como de la calibración de los umbrales diagnósticos. En sistemas altamente no estacionarios, donde dicho comportamiento evoluciona de forma significativa a lo largo del tiempo, será necesario incorporar mecanismos de actualización adaptativa de la distribución de referencia T_0 que permitan preservar su carácter representativo sin introducir sesgos derivados de posibles observaciones maliciosas. En segundo lugar, el enfoque no pretende sustituir a otros mecanismos de detección existentes, sino complementarlos, actuando como una capa adicional de análisis estructural que ayude a priorizar, contextualizar o interpretar alertas generadas por otros componentes del sistema.

Finalmente, resulta relevante señalar que las propiedades diagnósticas utilizadas en este trabajo, como la coherencia estructural, la persistencia temporal y la estabilidad del patrón de ruptura, podrían no ser exclusivas del ámbito de la ciberseguridad. Estas propiedades emergen de forma natural al analizar sistemas complejos en condiciones de observabilidad parcial y toma de decisiones agregadas, y coinciden con principios que están siendo explorados de manera independiente en otras áreas de la confiabilidad operacional, incluyendo la interpretación estructural de la equidad algorítmica. Esta convergencia preliminar sugiere que la pérdida de simetrías estructurales podría constituir un indicador transversal de degradación sistémica, manifestándose como anomalías, ineficiencias o comportamientos no alineados, incluso en ausencia de actividad ofensiva explícita.

Este trabajo consolida una evolución progresiva dentro de la vigilancia estructural en ciberseguridad. Mientras que estudios anteriores se centraban en detectar la existencia de rupturas ecosistémicas mediante medidas estadísticas o activaciones multivariables, la propuesta actual introduce un marco explícito de diagnóstico estructural que analiza no sólo la aparición de la ruptura, sino su forma, estabilidad y persistencia en el tiempo. Este salto metodológico transforma la ruptura en un objeto de decisión operativa, no meramente en una señal de alarma, y permite interpretar su naturaleza con mayor precisión, incluso en entornos parcialmente observables. De este modo, el enfoque propuesto no sólo amplía el alcance de la detección estructural previa, sino que la refuerza con capacidades de discriminación y explicabilidad directamente aplicables a sistemas reales.

VII. CONCLUSIONES

Este trabajo se enmarca dentro de una línea de investigación orientada a la detección temprana de ciberataques desde una perspectiva cibernética y ecosistémica, en la que el comportamiento de los sistemas digitales se analiza como un equilibrio dinámico sujeto a perturbaciones adversarias. En este contexto, se ha abordado una limitación clave de los enfoques de detección estructural existentes, concretamente la dificultad para discriminar entre adaptaciones funcionales legítimas y perturbaciones ofensivas cuando ambas se manifiestan como rupturas del equilibrio estadístico.

Como contribución principal, el artículo propone un criterio de diagnóstico estructural no supervisado que permite interpretar las rupturas ecosistémicas a partir de propiedades estructurales complementarias, coherencia multivariable, persistencia temporal y estabilidad del patrón de ruptura. Este criterio transforma la detección estructural en un proceso de diagnóstico operativo, capaz de reducir la ambigüedad inherente a entornos complejos y dinámicos, y de proporcionar evidencias interpretables que apoyen la toma de decisiones en ciberseguridad.

El enfoque presentado es ligero, interpretable e independiente del dominio, y resulta compatible con marcos previos de detección estructural sin requerir datos etiquetados ni procesos de entrenamiento adicionales. Su aplicabilidad se ha validado empíricamente mediante la ejecución de experimentos sobre entornos previamente utilizados en detección de intrusiones y aprendizaje federado, mostrando cómo el diagnóstico estructural permite reforzar el valor práctico de mecanismos de detección temprana ya existentes sin necesidad de redefinir los escenarios experimentales.

Este trabajo no pretende constituir un punto final, sino consolidar una etapa dentro de una línea de investigación más amplia. Como líneas futuras, se plantea profundizar en mecanismos de adaptación dinámica de la distribución de referencia en entornos altamente no estacionarios, así como en la integración del diagnóstico estructural con técnicas locales de detección para conformar estrategias híbridas. Asimismo, resulta de interés ampliar su validación a escenarios y dominios adicionales, así como explorar comparaciones sistemáticas con otros enfoques no supervisados, junto con su despliegue en entornos operativos reales, donde la capacidad de identificar precozmente entre deriva funcional y actividad ofensiva constituye un requisito fundamental para una ciberseguridad resiliente y sostenible.

AGRADECIMIENTOS

Esta publicación no habría sido posible sin el apoyo de los siguientes proyectos: Di4SPDS (PCI2023145980-2), financiado por MCIN/AEI/ 10.13039/501100011033 Unión Europea (Chist-Era Program); KOSMOS-UCLM (PID2024-155363OB-C44) financiado por MCIN/AEI/10.13039/ 501100011033/ FEDER, UE; AURORA (SBPLY/24/180225/000074), financiado por la Consejería de Educación, Cultura y Deportes de la Junta de Comunidades de Castilla La Mancha, y el Fondo Europeo de Desarrollo Regional FEDER (Programa Operativo de Castilla-La Mancha 2021–2027); RADAR (2025-GRIN-38447) financiado por FEDER; y RED2024-154240-T financiado por MICIU/AEI/10.13039/501100011033.

REFERENCIAS

- [1] M. M. Issa, M. Aljanabi, and H. M. Muhialdeen, "Systematic literature review on intrusion detection systems: Research trends, algorithms, methods, datasets, and limitations," *Journal of Intelligent Systems*, vol. 33, no. 1, p. 20230248, 2024.
- [2] M. Macas, C. Wu, and W. Fuertes, "Adversarial examples: A survey of attacks and defenses in deep learning-enabled cybersecurity systems," *Expert Systems with Applications*, vol. 238, p. 122223, 2024.
- [3] C. M. Braga Ortuño, M. A. Serrano, and E. Fernández-Medina, "Early detection of backdoor attacks in federated learning via ecosystemic symmetry breaking," in *Proceedings of the IEEE/ACM 12th International Conference on Big Data Computing, Applications and Technologies*, 2025, pp. 1–6.
- [4] N. Wiener, *The human use of human beings: Cybernetics and society*. Cambridge, MA: The Riverside Press, 1950.
- [5] C. M. Braga, M. A. Serrano, and E. Fernández-Medina, "Towards a methodology for ethical artificial intelligence system development: A necessary trustworthiness taxonomy," *Expert Systems with Applications*, vol. 286, p. 128034, 2025.
- [6] C. M. Braga, Ángel Suarez-Bárcena, M. A. Serrano, and E. Fernández-Medina, "TrustAIoT: A framework for building trustworthy AIoT platforms," *Internet of Things*, vol. 34, p. 101751, 2025.
- [7] C. M. Braga, M. A. Serrano, and E. Fernández-Medina, "Cibernética inversa: detección estructural de ciberataques mediante ruptura de simetría ecosistémica," in *Actas de la XIX Reunión Española sobre Criptología y Seguridad de la Información (RECSI 2026)*. Tenerife, España: Universidad de La Laguna, 2026, pp. 142–147. [Online]. Available: <https://cryptull.webs.ull.es/RECSI2026/LibrodeActasRECSI2026.pdf>
- [8] S. M. Alhidaifi, M. R. Asghar, and I. S. Ansari, "A survey on cyber resilience: Key strategies, research challenges, and future directions," *ACM computing surveys*, vol. 56, no. 8, pp. 1–48, 2024.
- [9] L. Devroye, L. Györfi, and G. Lugosi, *A probabilistic theory of pattern recognition*. New York: Springer Science & Business Media, 2013, vol. 31.
- [10] A. L. Gibbs and F. E. Su, "On choosing and bounding probability metrics," *International Statistical Review*, vol. 70, no. 3, pp. 419–435, 2002.
- [11] E. Bagdasaryan, A. Veit, Y. Hua, D. Estrin, and V. Shmatikov, "How to backdoor federated learning," in *Proceedings of the 23rd International Conference on Artificial Intelligence and Statistics (AISTATS 2020)*, ser. Proceedings of Machine Learning Research, vol. 108. Palermo, Italy: PMLR, 2020, pp. 2938–2948.
- [12] G. J. Székely and M. L. Rizzo, "Energy statistics: A class of statistics based on distances," *Journal of statistical planning and inference*, vol. 143, no. 8, pp. 1249–1272, 2013.
- [13] C. Villani, *Optimal transport: Old and new*. Berlin: Springer, 2008, vol. 338.

A review of: “An Extensible and Scalable System for Hash Lookup and Approximate Similarity Search with Similarity Digest Algorithms”

Daniel Huici, Ricardo J. Rodríguez, Eduardo Mena

Dpto. Informática e Ing. de Sistemas, Universidad de Zaragoza, Zaragoza, Spain

Email: {dhuici, ricardo, emena}@unizar.es

Abstract—Efficient analysis of large digital data volumes is a major challenge in digital forensics. To quickly identify relevant artifacts, we introduce APOTHEOSIS, an extensible approximate similarity search system designed for high scalability. Our system integrates Similarity Digest Algorithms (SDA) with advanced search data structures, leveraging a space-saving radix tree for exact matches and a custom Hierarchical Navigable Small World graph for fast approximate nearest neighbor searches. We demonstrate the system’s effectiveness through two case studies: first, detecting duplicate or plagiarized code within a source-code dataset; second, evaluating its scalability on a large memory artifact dataset from various Microsoft Windows versions. Our evaluation proves that APOTHEOSIS efficiently handles massive datasets while enabling analysts to evaluate and compare different SDAs across diverse forensic scenarios.

Index Terms—Digital forensics, similarity hashing, approximate matching, hash lookup, similarity search

Type of contribution: *Already published research* [1].

I. INTRODUCTION

The exponential growth of digital data and the proliferation of heterogeneous devices have significantly increased the complexity of digital forensic investigations. Analysts must inspect large collections of files, logs, and memory dumps in which every artifact may be relevant. Exact hashing is a useful building block for quickly identifying known artifacts, but it fails when content changes slightly (e.g., recompilation, reformatting, patching). Similarity Digest Algorithms (SDA) [2] address this limitation by generating digests whose comparisons yield a similarity score between artifacts, enabling the detection of near duplicates or derived content.

However, SDA-based search at scale is computationally expensive if implemented as brute-force comparison against all stored digests. Our original paper introduces APOTHEOSIS, an extensible system that combines exact hash lookup and scalable approximate similarity search over SDA digests.

II. BACKGROUND

The core mechanism of APOTHEOSIS relies on the synergy between Similarity Digest Algorithms (SDA) and advanced search data structures to process digital forensics data at scale.

SDA treat inputs as byte streams and produce digests (or fingerprints) that preserve similarity under certain transformations. In our evaluation we use ssdeep (feature-sequence hashing, with similarity in $[0, 100]$) [3] and TLSH (locality-sensitive hashing) [4]. Because SDA effectiveness depends on the underlying artifacts, a given algorithm may behave differently on source code, binaries, or memory pages.

To support efficient search, APOTHEOSIS combines two well-known data structures. First, a radix tree (or compressed trie) stores digests to support fast exact and prefix-based lookup [5], with time complexity depending on the hash length rather than the collection size. Second, a Hierarchical Navigable Small World (HNSW) graph provides approximate K -nearest neighbor search [6]. Standard HNSW libraries assume continuous vector spaces and typical distance metrics; APOTHEOSIS instead uses SDA-specific scoring functions as the similarity primitive.

III. SYSTEM DESCRIPTION

APOTHEOSIS is organized around two phases. During *indexing* phase, artifacts are processed by an SDA, producing digests that are inserted into (i) a radix tree for exact lookup and (ii) an HNSW graph for approximate search. Extended metadata (e.g., file names, OS version, module information) are stored in a database and referenced from the HNSW nodes, keeping the graph compact. During *querying* phase, the system first checks the radix tree for exact matches; if none are found, or if similarity search is requested, it runs HNSW search to retrieve the top- K candidates.

APOTHEOSIS supports two search modes: nearest-neighbor search (retrieve the K most similar digests) and threshold-based search (retrieve digests whose similarity score satisfies a constraint relative to a threshold t).

IV. EVALUATION

A. Case Study 1: Plagiarism detection

Our first case study assesses the effectiveness of APOTHEOSIS in detecting duplicate or plagiarized code. We use a dataset of 43 792 source-code files from student programming assignments [7]. Because the dataset does not provide explicit similarity thresholds, we compute pairwise scores with ssdeep and TLSH and derive several thresholded ground truths. For each SDA we build an APOTHEOSIS model and compare it against a MinHashLSH baseline [8].

In Fig. 1 we evaluate accuracy, precision, recall and F1-score across similarity thresholds. We show these metrics for APOTHEOSIS with ssdeep and TLSH, together with the MinHashLSH baseline.

APOTHEOSIS achieves a precision of 1.00 for both ssdeep and TLSH in all evaluated thresholds, while recall and F1-score improve for stricter similarity criteria. TLSH consistently provides higher recall and F1 than ssdeep in this scenario, making it preferable for text/code duplication




Figure 1. Performance metrics (accuracy, precision, recall, F1) for APOTHEOSIS with ssdeep and TLSH, and MinHash+LSH, across different similarity thresholds.

detection. MinHashLSH shows more irregular behavior and struggles to capture exact matches due to its probabilistic nature.

B. Case Study 2: Scalability on Windows memory pages

The second case study focuses on scalability using a dataset of approximately 4.2 million memory pages belonging to around 37500 Windows system files. Each page is hashed with TLSH and the resulting digests are indexed by APOTHEOSIS. We measure average insertion time, exact lookup time, and approximate K -nearest neighbor search time while varying HNSW configuration parameters.

In Fig. 2, we show the curve fitting for the approximate K -NN operation across three different APOTHEOSIS configurations as the dataset size grows. The experiments show that approximate search times grow roughly logarithmically with the number of indexed elements, in line with the theoretical complexity of HNSW. A sensitivity analysis with these configurations confirms that connectivity parameters affect both recall and resource usage, but that APOTHEOSIS can sustain interactive query times even at millions of entries.

V. CONCLUSIONS

APOTHEOSIS demonstrates that it is possible to combine exact hash lookup and approximate similarity search in a single, extensible system suitable for digital forensics. By leveraging a radix tree and a customized HNSW graph, the system provides high-precision duplication detection and scalable approximate search over millions of similarity digests. The case studies highlight both its effectiveness on text/code artifacts and its ability to index large Windows memory datasets while preserving low latency.

Beyond the two scenarios presented here, the design is SDA-agnostic and can support other algorithms or artifact types as long as an intermediate digest can be computed. Future lines of work include exploring alternative approximate-nearest-neighbor structures, further automating parameter tuning, and integrating APOTHEOSIS into end-to-end forensic analysis workflows and tools.




Figure 2. Curve fitting for the approximate K -NN operation for dataset sizes $N \in [100, 50000]$ for three different APOTHEOSIS configurations.

ACKNOWLEDGMENTS

This research was supported in part by grants PID2020-113903RB-I00 (KIT-IA) and PID2023-151467OA-I00 (CRAPER), funded by MICIU/AEI/10.13039/501100011033 and by ERDF/EU, by grant TED2021-131115A-I00 (MIMFA), funded by MICIU/AEI/10.13039/501100011033 and by the European Union NextGenerationEU/PRTR, by grant *Proyecto Estratégico Ciberseguridad EINA UNIZAR*, funded by the Spanish National Cybersecurity Institute (INCIBE) and the European Union NextGenerationEU/PRTR, by grant *Programa de Proyectos Estratégicos de Grupos de Investigación* (DisCo and SID research groups, refs. T21-23R and T42-23R, respectively), funded by the University, Industry and Innovation Department of the Aragonese Government.

REFERENCES

- [1] D. Huici, R. J. Rodríguez, and E. Mena, “Apotheosis: An efficient approximate similarity search system,” *SoftwareX*, vol. 29, p. 102016, 2025.
- [2] F. Breiteringer, B. Guttman, M. McCarrin, V. Roussev, and D. White, “Approximate Matching: Definition and Terminology,” National Institute of Standards and Technology, techreport NIST Special Publication 800-168, May 2014.
- [3] J. Kornblum, “Identifying almost identical files using context triggered piecewise hashing,” *Digital Investigation*, vol. 3, pp. 91–97, 2006, the Proceedings of the 6th Annual Digital Forensic Research Workshop (DFRWS ’06).
- [4] J. Oliver, C. Cheng, and Y. Chen, “TLSH – A Locality Sensitive Hash,” in *2013 Fourth Cybercrime and Trustworthy Computing Workshop*. IEEE, 2013, pp. 7–13.
- [5] D. R. Morrison, “PATRICIA—Practical Algorithm To Retrieve Information Coded in Alphanumeric,” *Journal of the ACM (JACM)*, vol. 15, pp. 514–534, 1968.
- [6] Y. A. Malkov and D. A. Yashunin, “Efficient and Robust Approximate Nearest Neighbor Search Using Hierarchical Navigable Small World Graphs,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 42, no. 4, pp. 824–836, 2020.
- [7] V. Ljubovic, “Programming Homework Dataset for Plagiarism Detection,” [Online; <https://dx.doi.org/10.21227/71fw-ss32>], May 2020, accessed on September 28, 2024.
- [8] A. Broder, “On the resemblance and containment of documents,” in *Proceedings. Compression and Complexity of SEQUENCES 1997 (Cat. No.97TB100171)*, 1997, pp. 21–29.

HDDAF: Un Framework para la Detección y Adaptación de Drift en Sistemas de Detección de Amenazas Basados en Inteligencia Artificial

Antonio Lara-Gutierrez
NICS Lab
Universidad de Málaga
alara@uma.es

Carmen Fernandez-Gago
NICS Lab
Universidad de Málaga
mcgago@uma.es

Jose A. Onieva
NICS Lab
Universidad de Málaga
onieva@uma.es

Resumen—La fiabilidad de los sistemas de detección de intrusiones (NIDS) basados en Inteligencia Artificial decae inevitablemente ante la volatilidad de los entornos de red, afectados por la evolución natural del tráfico (*Concept* y *Feature Drift*) y la manipulación maliciosa. Si bien estos fenómenos surgen de diferentes procesos subyacentes, todos comparten el efecto de provocar un desajuste distribucional entre los datos operativos y los datos de entrenamiento del modelo. Este estudio presenta HDDAF (*Hybrid Drift Detection and Adaptation Framework*), una arquitectura unificada que mitiga estos desafíos simultáneamente dentro de un mismo ciclo de vida adaptativo. A diferencia de enfoques aislados, HDDAF integra un motor de detección híbrido capaz de distinguir entre desviaciones estadísticas benignas y perturbaciones adversarias, orquestando respuestas autónomas de reentrenamiento o alerta de seguridad. Validado en el dataset CIC-IDS2017, el sistema mantiene un F1-Score base del 99,89 % y recupera niveles superiores al 96 % en distintos escenarios adversos, demostrando una adaptación robusta en tiempo real.

Index Terms—Inteligencia Artificial, Concept Drift, Feature Drift, Ataques Adversarios

Tipo de contribución: Investigación ya publicada [1]

I. INTRODUCCIÓN

La volatilidad inherente a los entornos de red expone a los NIDS basados en IA a tres fenómenos que erosionan progresivamente su eficacia operativa. Como demostramos en el trabajo original [1], la divergencia distribucional observada entre los datos de entrenamiento y los datos operativos acaba comprometiendo la viabilidad de estos sistemas en despliegues reales. El primero de dichos fenómenos, el *Concept Drift*, analizado por Xiang et al. (2023) [2], desplaza la frontera de decisión ideal al evolucionar la relación $P(y | x)$ entre datos y etiquetas. Simultáneamente, el *Feature Drift* altera la distribución estadística marginal $P(x)$ de características, pudiendo ser malinterpretado como anomalía. Finalmente, la robustez se ve amenazada por ataques adversarios, donde se inyectan perturbaciones deliberadas para evadir la detección o modificar la frontera de decisión de los modelos [3].

Frente a los enfoques actuales que abordan estos retos de forma aislada, Zhang et al. (2024) [4] detectan *drift* pero carecen de mecanismo de defensa adversaria, mientras que Zhao et al. (2024) [5] emplean GANs únicamente para aumentación de datos sin adaptación ante *drift*, presentamos HDDAF (*Hybrid Drift Detection and Adaptation Framework*). Esta arquitectura integra detección y defensa en un único ciclo de vida, distinguiendo si la degradación responde a una

evolución estadística o a una manipulación, y garantizando la sostenibilidad del sistema sin supervisión humana constante.

II. ARQUITECTURA DEL FRAMEWORK HDDAF

Como se ilustra en la Fig. 1, el sistema HDDAF se articula como una arquitectura modular y escalable diseñada mediante tres etapas críticas interconectadas.

II-A. Preprocesamiento y Sanitización Híbrida

En esta etapa, el framework aborda el desbalance de clases mediante *Synthetic Minority Oversampling Technique* (SMOTE) y usa *Information Gain* (IG) para la selección de las 32 variables más influyentes. IG fue preferido sobre PCA por su mayor interpretabilidad y su menor coste computacional en flujos de alta dimensionalidad. Como novedad, implementa una técnica de Entrenamiento Adversario Híbrido que optimiza la limpieza de datos: primero utiliza *K-Means* para aislar valores atípicos y, posteriormente, aplica la validación RONI exclusivamente a estos clústeres sospechosos. Esta estrategia reduce significativamente el coste computacional respecto al método tradicional, manteniendo una alta precisión en la eliminación de muestras envenenadas.

II-B. Modelo Híbrido Multicapa (MLHA)

El motor de detección implementa una arquitectura jerárquica diseñada para capturar patrones de tráfico complejos y no lineales. Una red neuronal procesa el tráfico en paralelo con un ensamble de *Random Forest* y *LightGBM*. Finalmente, las predicciones son unificadas por un meta-clasificador de Regresión Logística ($NN + LR[RF + LGBM]$), una arquitectura que maximiza la capacidad de generalización y minimiza la tasa de falsos positivos.

II-C. Adaptación Activa ante Concept y Feature Drift

El *Mixed-Drift Handling Module* monitoriza el flujo de datos mediante el método de Hoeffding para detección de *drift* (*Hoeffding Drift Detection Method*, HDDM). Al detectar desviaciones, el sistema discrimina su naturaleza: ante *Concept Drift*, ejecuta *fine-tuning* o reentrenamiento completo según la severidad; mientras que ante *Feature Drift*, recalcula dinámicamente la importancia de las características mediante IG. Adicionalmente, un modelo generativo basado en GANs sintetiza escenarios de *drift* futuros, entrenado para ello sobre ventanas de datos históricos con *drift* etiquetado, e integra las




Figura 1. Arquitectura del Framework de Detección y Adaptación de Drift Híbrido (HDDAF) [1].

muestras generadas en el ciclo de *fine-tuning*, permitiendo el endurecimiento preventivo del sistema ante amenazas reales.

III. EVALUACIÓN EXPERIMENTAL

La validación empírica, realizada sobre el dataset CIC-IDS2017, comenzó contrastando múltiples configuraciones de clasificadores, técnicas de balanceo y selección de características. Los resultados confirman que el modelo híbrido propuesto $NN + LR[RF + LGBM]$ combinado con SMOTE e IG constituye la configuración óptima. Esta arquitectura alcanzó un F1-Score de 0.9989, superando a modelos individuales y reduciendo el tiempo de entrenamiento en un 78 % (62,5 s frente a 285,4 s) respecto a la configuración con PCA.

Posteriormente, se evaluó la adaptabilidad del framework bajo escenarios de estrés que simulaban *Concept Drift* (gradual, abrupto y recurrente) y *Feature Drift*. El sistema demostró una resiliencia robusta, recuperando niveles de precisión superiores al 96 % tras la activación automática de los mecanismos de *fine-tuning* o reentrenamiento completo. Frente a ataques de envenenamiento de datos (*poisoning*), la técnica de sanitización híbrida mantuvo la precisión y redujo el Error Cuadrático Medio (MSE) prácticamente a cero, neutralizando hasta el 90 % de muestras adversarias probadas.

Finalmente, un estudio de ablación ratificó la necesidad de la arquitectura completa: la desactivación del módulo de entrenamiento adversario, por ejemplo, provocó una caída de la precisión *post-drift* hasta el 75 %. Estas pruebas funcionales se complementaron con una evaluación de rendimiento en tiempo real, donde HDDAF procesó un flujo continuo de tráfico alcanzando un *throughput* de 3.193 flujos/s con una latencia media de apenas 0,31 ms/flujo. La Tabla I sintetiza las métricas críticas obtenidas durante estas fases experimentales.

Tabla I
RESUMEN CONSOLIDADO DE RESULTADOS EXPERIMENTALES.

Área	Métrica (Unidad)	Resultado
Rendimiento Base	F1-Score (%)	99,89 (Modelo Híbrido)
Eficiencia	T. Entren. (s)	62,50 ($\Delta 78\%$)
Concept Drift	Prec. Recup. (%)	97,75 (Reentrenamiento)
Feature Drift	Prec. Recup. (%)	94,02 (Eliminación)
Robustez	Detección (0-1)	0,92 (Adversarias)
Tiempo Real	Caudal (flujos/s)	3.193 (Latencia 0,31 ms)

IV. CONCLUSIONES

HDDAF es un framework modular que unifica la detección de amenazas con una capacidad de adaptación autónoma frente a la evolución del tráfico y la manipulación adversaria. Los resultados confirman que la arquitectura habilita el despliegue de NIDS resilientes y sostenibles en entornos operativos reales. Este enfoque establece una base robusta para futuras líneas de investigación orientadas hacia la explicabilidad del *drift*, la integración de aprendizaje semi-supervisado para reducir la dependencia de datos etiquetados en el reentrenamiento, y la optimización del ensamble híbrido para dispositivos de *edge computing* con recursos limitados.

AGRADECIMIENTOS

Esta publicación forma parte del proyecto “CiberIA: Investigación e Innovación para la Integración de Ciberseguridad e Inteligencia Artificial” (Proyecto C079/23), financiado por la “Unión Europea NextGeneration-EU, Plan de Recuperación, Transformación y Resiliencia”, a través de INCIBE. Asimismo, ha sido parcialmente apoyada por el proyecto SecAI (PID2022-139268OB-I00), financiado por el Ministerio de Ciencia e Innovación y la Agencia Estatal de Investigación; y por la Universidad de Málaga para su presentación.

REFERENCIAS

- [1] A. Lara-Gutierrez, C. Fernandez-Gago, and J. A. Onieva, “A Framework for Drift Detection and Adaptation in AI-driven Anomaly and Threat Detection Systems,” *International Journal of Information Security*, vol. 24, no. 5, p. 199, Sep. 2025. [Online]. Available: <https://doi.org/10.1007/s10207-025-01118-9>
- [2] Q. Xiang, L. Zi, X. Cong, and Y. Wang, “Concept Drift Adaptation Methods under the Deep Learning Framework: A Literature Review,” *Applied Sciences*, vol. 13, no. 11, p. 6515, 5 2023. [Online]. Available: <https://doi.org/10.3390/app13116515>
- [3] X. Yuan, S. Han, W. Huang, H. Ye, X. Kong, and F. Zhang, “A simple framework to enhance the adversarial robustness of deep learning-based intrusion detection system,” *Computers & Security*, vol. 137, p. 103644, Feb. 2024. [Online]. Available: <http://dx.doi.org/10.1016/j.cose.2023.103644>
- [4] H. Zhang, X. Chen, M. Hu, and V. Sugumaran, “Multilayer concept drift detection method based on model explainability,” *IEEE Access*, p. 1–1, 2024. [Online]. Available: <http://dx.doi.org/10.1109/ACCESS.2024.3517697>
- [5] X. Zhao, K. W. Fok, and V. L. Thing, “Enhancing network intrusion detection performance using generative adversarial networks,” *Computers & Security*, vol. 145, p. 104005, Oct. 2024. [Online]. Available: <http://dx.doi.org/10.1016/j.cose.2024.104005>

A Review of: “A Hybrid EFMS-KMeans and CNN-GRU Architecture for Anomaly Detection in Encrypted Network Traffic.”

Daniel Quirumbay Yagual
CITIC
University of A Coruña,
15071 A Coruña, Spain
daniel.quirumbay@udc.es

Diego Fernández Iglesias
CITIC
University of A Coruña,
15071 A Coruña, Spain
diego.fernandez@udc.es

Francisco J. Nóvoa
CITIC
University of A Coruña,
15071 A Coruña, Spain
francisco.javier.novoa@udc.es

Resumen—Este trabajo presenta una arquitectura híbrida para la detección de anomalías en tráfico de red cifrado, basada en la integración de EFMS-KMeans y un modelo secuencial CNN-GRU, validada con datos reales de firewall. El enfoque combina segmentación no supervisada para la generación automática de etiquetas con aprendizaje profundo para capturar patrones espaciales y temporales. Se propone un pipeline que incluye limpieza, ingeniería de características y variables conductuales, reduciendo la dependencia de anotaciones manuales. Para mitigar el desbalance de clases, se emplea SMOTE sobre una versión balanceada del dataset, mejorando la estabilidad del aprendizaje; no obstante, los resultados se analizan bajo condiciones balanceadas. El desempeño se evalúa considerando también la distribución original del tráfico, proporcionando una estimación más realista. Los resultados evidencian un equilibrio adecuado entre detección de anomalías y control de falsas alarmas en entornos con tráfico cifrado.

Index Terms—Análisis del comportamiento, agrupamiento, computación de borde, aprendizaje profundo híbrido, detección de intrusiones.

Tipo de contribución: Investigación ya publicada

I. INTRODUCCIÓN

La ciberseguridad se ha consolidado como un elemento esencial para la protección de infraestructuras digitales y redes heterogéneas. El aumento en la complejidad y capacidad de evasión de los ciberataques ha evidenciado las limitaciones de los sistemas tradicionales basados en firmas y reglas estáticas, especialmente en entornos donde el tráfico cifrado mediante HTTPS dificulta la inspección profunda de paquetes [1].

En respuesta a estos desafíos, los enfoques basados en inteligencia artificial han demostrado una elevada capacidad para modelar patrones complejos en datos dinámicos y cifrados, superando las restricciones de los métodos convencionales [1], [2]. En particular, las arquitecturas híbridas que combinan clustering no supervisado con modelos secuenciales profundos permiten capturar tanto características estructurales como dependencias temporales en los flujos de red, mejorando la precisión y la generalización en escenarios reales [1], [3].

Asimismo, la calidad y representatividad del dataset constituyen factores determinantes en el desempeño de los sistemas de detección. El uso de registros reales de firewall, junto con técnicas de ingeniería de características y balanceo de clases, favorece la identificación robusta de patrones anómalos en tráfico heterogéneo y cifrado [1].

En este contexto, este trabajo resume una investigación previamente publicada que propone una arquitectura híbrida basada en EFMS-KMeans y CNN-GRU para la detección de anomalías en tráfico de red cifrado, validada con datos reales y técnicas avanzadas de preprocesamiento, evidenciando alta precisión y robustez en entornos dinámicos [1].

A diferencia de trabajos previos, este estudio integra pseudo-etiquetado no supervisado basado en EFMS-KMeans con un modelo CNN-GRU y un pipeline orientado a tráfico cifrado real. Asimismo, incorpora una evaluación más rigurosa que contempla tanto datos balanceados como la distribución original, permitiendo una estimación más representativa del desempeño.

II. METODOLOGÍA Y ARQUITECTURA HÍBRIDA PROPUESTA

El enfoque propuesto se basa en una arquitectura híbrida para la detección de anomalías en tráfico de red cifrado, que integra segmentación no supervisada mediante *EFMS-KMeans* con modelado secuencial profundo a través de una red *CNN-GRU*. Esta combinación permite capturar patrones estructurales en el espacio de características y dependencias temporales en secuencias de tráfico, superando limitaciones de métodos tradicionales basados en firmas o enfoques supervisados aislados [1], [3].

El dataset se construyó a partir de registros reales de un firewall perimetral, representando entornos operacionales con tráfico administrativo, académico e IoT. Los datos fueron sometidos a limpieza, normalización, codificación e ingeniería de características conductuales. Para mitigar el desbalance inherente al tráfico real, se aplicó SMOTE, mejorando la estabilidad del aprendizaje supervisado [1], [4].

En la primera fase, *EFMS-KMeans* realiza la segmentación no supervisada mediante estimación de centros densos, generando pseudo-etiquetas sin anotación manual. Estas alimentan al modelo *CNN-GRU*, donde la capa convolucional extrae patrones locales y la unidad GRU modela dependencias temporales [2]. La arquitectura incluye reducción de dimensionalidad, regularización mediante *dropout* y una capa sigmoide para clasificación binaria [1].

La integración de clustering no supervisado, balanceo de datos e inteligencia profunda mejora la robustez frente a

tráfico cifrado y variabilidad temporal, ofreciendo una solución escalable para infraestructuras modernas. En esta línea, enfoques híbridos han demostrado efectividad en registros reales de firewall [5]. Metodológicamente, SMOTE se plantea para aplicarse sobre el conjunto de entrenamiento tras la partición de los datos, evitando data leakage; sin embargo, en este estudio los resultados se analizan sobre una versión balanceada del dataset bajo condiciones controladas.

III. RESULTADOS

La validación experimental se realizó con registros reales de un firewall perimetral, evaluando el modelo en un entorno heterogéneo con tráfico administrativo, académico e IoT [1], [2]. El análisis se basó en una versión balanceada mediante SMOTE, lo que permitió estudiar el comportamiento del modelo bajo condiciones controladas [4]. En consecuencia, las métricas reportadas deben interpretarse como una estimación superior del desempeño. La evaluación sobre la distribución original del tráfico, más representativa de escenarios operacionales, se reconoce como una limitación del presente estudio y se plantea como línea futura de investigación.

El desempeño de la arquitectura híbrida EFMS-KMeans + CNN-GRU se evaluó mediante métricas estándar (*Accuracy*, *Precision*, *Recall* y *F1-score*). Los resultados evidencian alta capacidad de discriminación entre tráfico normal y anómalo, con mejora en generalización frente a enfoques recientes [3], [5]. La matriz de confusión (Fig. 1) muestra baja tasa de falsos positivos y adecuada identificación de patrones anómalos.

El clustering con EFMS-KMeans generó pseudo-etiquetas coherentes que fortalecieron el entrenamiento supervisado, mejorando la sensibilidad incluso bajo desbalance de clases [1], [2]. La Tabla I resume métricas tras el balanceo, evidenciando un comportamiento equilibrado y robusto.

En conjunto, los resultados confirman que la arquitectura propuesta mantiene un equilibrio entre precisión, robustez y generalización, demostrando su efectividad en la detección de anomalías en tráfico cifrado [1].

Tabla I
CLASIFICACIÓN DE EFMS-KMEANS DESPUÉS DEL BALANCEO SMOTE.

Class	Precision	Recall	F1-Score	Support
Normal (0)	0.96	1.00	0.98	180,482
Anomalous (1)	1.00	0.95	0.98	181,109
Macro avg	0.98	0.98	0.98	361,591
Weighted avg	0.98	0.98	0.98	361,591




Figura 1. Matriz de Confusión del Modelo CNN-GRU con SMOTE.

IV. DISCUSIÓN

Los resultados evidencian que la integración de EFMS-KMeans con CNN-GRU es eficaz para la detección de anomalías en tráfico cifrado, al capturar patrones espaciales y temporales y reducir la dependencia de datos etiquetados [1], [2]. La validación con tráfico real muestra robustez frente a la variabilidad y el desbalance de clases, mientras que SMOTE mejora la estabilidad del entrenamiento y reduce falsos positivos [4]. Asimismo, la combinación de clustering no supervisado y aprendizaje profundo optimiza la segmentación y la generalización, superando enfoques supervisados [3], en línea con arquitecturas híbridas recientes [5].

No obstante, la evaluación sobre un dataset balanceado mediante SMOTE puede introducir sesgo optimista y limitar su representatividad en escenarios reales. La ausencia de evaluación sobre la distribución original restringe el análisis de métricas críticas como la FPR. Por ello, futuras evaluaciones deben evitar *data leakage* mediante separación previa de datos e incorporar métricas como PR-AUC, FPR y análisis de umbral.

V. CONCLUSIONES

Este trabajo presenta una arquitectura híbrida basada en EFMS-KMeans y CNN-GRU para la detección de anomalías en tráfico de red cifrado, validada con datos reales de firewall. La integración de clustering no supervisado, balanceo de datos y aprendizaje profundo mejora la segmentación del tráfico, la capacidad de generalización y la detección en entornos dinámicos y heterogéneos [1].

Los resultados confirman la efectividad del enfoque, evidenciando alta precisión y robustez frente a tráfico cifrado y desbalanceo de clases. En conjunto, la combinación de un dataset representativo y una arquitectura híbrida constituye una base sólida para sistemas inteligentes de detección de intrusiones en infraestructuras de red modernas [1]. Finalmente, se reconoce la importancia de evaluar estos modelos bajo condiciones de desbalance real, lo cual será abordado en trabajos futuros mediante protocolos experimentales más estrictos que permitan una validación más cercana a escenarios de despliegue.

AGRADECIMIENTOS

Este trabajo fue financiado por el Ministerio de Ciencia, Innovación y Universidades de España y el FEDER (Proyecto PID2023-150794OB-I00), así como por la Xunta de Galicia y la Unión Europea a través del Programa FEDER Galicia 2021-2027 (Subvenciones ED431B 2024/02 y ED431G 2023/01).

REFERENCIAS

- [1] D. Quirumbay Yagual, D. Fernández Iglesias, and F. J. Nóvoa, “A hybrid deep learning-based architecture for network traffic anomaly detection via EFMS-enhanced KMeans clustering and CNN-GRU models,” *Applied Sciences*, vol. 15, pp. 10889, 2025, doi: 10.3390/app152010889.
- [2] Y. Huo, Y. Cao, Z. Wang, Y. Yan, Z. Ge, and Y. Yang, “Traffic anomaly detection method based on improved GRU and EFMS-KMeans clustering,” *Comput. Model. Eng. Sci.*, vol. 126, pp. 1053–1091, 2021.
- [3] L. Mohammadpour, T. C. Ling, C. S. Liew, and A. Aryanfar, “A survey of CNN-based network intrusion detection,” *Appl. Sci.*, vol. 12, p. 8162, 2022.
- [4] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, “SMOTE: Synthetic minority over-sampling technique,” *J. Artif. Intell. Res.*, vol. 16, pp. 321–357, 2002.
- [5] A. Yılmaz and R. Daş, “A novel hybrid approach combining GCN and GAT for effective anomaly detection from firewall logs in campus networks,” *Comput. Netw.*, vol. 259, p. 111082, 2025.

Revisiting Network Traffic Foundation Models: A Systematic Review

Rubén Pérez-Jove^{1,2,*}, Cristian R. Munteanu^{1,2}, Julián Dorado^{1,2},
Alejandro Pazos^{1,2}, Jose Vázquez-Naya^{1,2}

¹ RNASA-IMEDIR, Universidade da Coruña, Facultad de Informática, Campus de Elviña, A Coruña, 15071, Spain

² Centro de Investigación CITIC, Universidade da Coruña, Campus de Elviña, A Coruña, 15071, Spain
{c.munteanu, julian.dorado, alejandro.pazos, jose}@udc.es

* Corresponding author: ruben.perez.jove@udc.es

Abstract—Network Traffic Foundation Models (NT-FMs) aim to enable a train-once, adapt-anywhere paradigm for automated traffic management. This extended abstract summarises a systematic review of 51 primary studies published between 2017 and 2025. We address four research questions: (RQ1) prevailing architectures and training regimes, (RQ2) traffic representations, (RQ3) application environments and tasks, and (RQ4) the availability of suitable datasets. The literature shows rapid growth in NT-FM research, with Transformers and self-supervised objectives dominating current designs. However, cross-task transfer is still limited, terabyte-scale public corpora remain scarce, and efficiency techniques are only starting to mature. Overall, NT-FMs appear feasible but are constrained by data scale and transferability. We conclude with open challenges and a research agenda toward scalable, robust, and reliable traffic foundation models.

Index Terms—Network Traffic, Foundation Models, Pretraining, Fine-tuning, Self-supervised Learning, Network Management, Network Security

Type of contribution: *Already published research*

I. INTRODUCTION

Contemporary networks demand automated traffic management to sustain performance, reliability, and security amid 5G/6G, IoT, and emerging technologies, which amplify traffic diversity and threat complexity. While ML/DL has advanced traffic analysis, most solutions remain task-specific, data-hungry, and hard to transfer across environments. Network Traffic Foundation Models (NT-FMs) propose pretraining on large, unlabeled traces to learn reusable traffic representations that can be adapted to multiple tasks with limited supervision. This extended abstract summarises our systematic review of 51 studies (2017–2025) [1], covering architectures, representations, applications, and datasets, and distils the main gaps and a research agenda for scalable, robust NT-FMs.

II. METHODOLOGY

We conducted a systematic literature review following established guidelines and adapted them to the AI and networking domains. We defined a main question on the feasibility of NT-FMs and four research questions covering architectures and training, traffic representations, application contexts, and datasets. Searches were run in Web of Science and Scopus for English works from 2017–2025, complemented with preprints and snowballing. Studies were screened with explicit inclusion and exclusion criteria emphasizing pretraining on network

traffic and evidence of generalisation, while removing duplicates, non-network data, and insufficiently detailed publications. The final corpus was refined through full-text review and selective updates from alerts and citation tracking.

III. RESULTS

A. Content Review

In the full paper, we group the literature into three categories: (i) pretraining and fine-tuning pipelines tailored to a single task or environment, (ii) full NT-FMs that aim for multi-task and cross-environment generalisation, and (iii) other relevant works that intersect with the topic but do not meet the inclusion criteria. In this extended abstract, we focus only on the main category: NT-FMs.

Full NT-FMs begin in 2022 with ET-BERT, which established the feasibility of pretraining on traffic and transferring to multiple tasks or configurations [2]. In 2023, the field expanded to multi-level representations (YaTC) and multimodal Transformers (netFound) [3], [4]. 2024 brought encoder-decoder hybrids and long-sequence generators such as Lens and TrafficGPT [5], [6]. Overall, the trajectory is from BERT-style masked objectives toward more diverse architectures and generation capabilities, while cross-domain generalisation remains limited.

B. Bibliometric Analysis

The review covers 51 primary studies, and output accelerates after 2022 with a peak in 2024 (Fig. 1). Conferences dominate while journals rise and preprints remain significant; venues are fragmented, and the split between full NT-FMs and task-specific pipelines is near parity. Publications are concentrated in Asia (notably China), followed by the United States and a long tail of single-paper contributors.

IV. DISCUSSION

A. Synthesis by Research Questions

1) *RQ1: Which AI architectures have been employed and how were they trained to develop NT-FMs?*: Transformers dominate NT-FMs, typically trained via self-supervised pretraining on unlabeled traffic followed by supervised fine-tuning on downstream tasks [2], [3], [4]. Variants include encoder-only (BERT-like) and encoder-decoder designs [5], [6].




Figure 1. Summary of the $n = 51$ studies: (a) year-by-year publication counts (2020–2025) and (b) overall publication types.

2) *RQ2: How is network traffic represented and encoded for input to NT-FMs?*: Most NT-FMs operate on flows, bursts, or packets, using raw bytes with optional metadata (headers, directions, timings). Tokenisation spans byte-level and protocol-aware schemes, often with positional and segment embeddings to preserve order and structure [2], [4]. Privacy concerns drive anonymisation or removal of identifiers. Sequence lengths remain constrained (typically a few hundred tokens or a handful of packets), with some models extending to longer contexts [6].

3) *RQ3: In which network environments and for which tasks have NT-FMs been applied?*: Evaluations span campus networks, ISP backbones, IoT testbeds, VPN/Tor traffic, and mobile app traces. Tasks concentrate on classification and security (malware, intrusion detection, encrypted service identification), with growing interest in traffic generation and limited exploration of forecasting.

4) *RQ4: Are there publicly available datasets suitable for training NT-FMs?*: Public datasets are sufficient for fine-tuning benchmarks but are often too small or narrow for true foundation-model pretraining. Only a few openly licensed corpora exceed terabyte scale; many large collections are proprietary or restricted, and some studies pretrain and fine-tune on splits of the same dataset, limiting evidence of cross-domain generalisation.

B. Future Research Trends and Directions

Future progress hinges on data diversity and rigorous cross-domain evaluation. Key needs include standardised tokenisation, benchmarks that separate pretraining and evaluation domains, and privacy-preserving evaluation frameworks. Architecturally, the field is moving toward linear-complexity models, longer context windows, and multimodal representations. Forecasting and network-wide optimisation remain under-explored compared to security tasks, pointing to opportunities in time-series and telemetry-focused NT-FMs.

V. CONCLUSION

Our review confirms that NT-FMs are feasible and already yield consistent gains over task-specific baselines in

classification and security. However, most current models are constrained by limited data diversity and narrow evaluation settings. The path to “train once, deploy everywhere” depends less on new architectures alone and more on broader, open, and representative data resources, along with standardised evaluation practices that demonstrate true cross-domain generalisation.

ACKNOWLEDGEMENTS

This work was supported by the grant ED431C 2022/46 - Competitive Reference Groups GRC - funded by “Xunta de Galicia” (Spain). This work was also supported by CITIC, as a center accredited for excellence within the Galician University System and a member of the CIGUS Network, which receives subsidies from the Department of Education, Science, Universities, and Vocational Training of the “Xunta de Galicia”. Additionally, CITIC is co-financed by the EU through the FEDER Galicia 2021–27 operational program (Ref. ED431G 2023/01). This work was also supported by the “Formación de Profesorado Universitario” (FPU) grant from the Spanish Ministry of Universities to Rubén Pérez Jove (Grant FPU22/04418).

REFERENCES

- [1] R. Pérez-Jove, C. R. Munteanu, J. Dorado, A. Pazos, and J. Vázquez-Naya, “Network traffic foundation models: A systematic review,” *Computer Networks*, vol. 276, p. 111998, Feb. 2026.
- [2] X. Lin, G. Xiong, G. Gou, Z. Li, J. Shi, and J. Yu, “ET-BERT: A Contextualized Datagram Representation with Pre-training Transformers for Encrypted Traffic Classification,” in *Proceedings of the ACM Web Conference 2022*. ACM, 2022, pp. 633–642.
- [3] R. Zhao, M. Zhan, X. Deng, F. Li, Y. Wang, Y. Wang, G. Gui, and Z. Xue, “A Novel Self-Supervised Framework Based on Masked Autoencoder for Traffic Classification,” *IEEE/ACM Transactions on Networking*, vol. 32, no. 3, pp. 2012–2025, 2024.
- [4] S. Guthula, N. Battula, R. Beltiukov, W. Guo, and A. Gupta, “netFound: Foundation Model for Network Security,” 2023.
- [5] Q. Wang, C. Qian, X. Li, Z. Yao, and H. Shao, “Lens: A Foundation Model for Network Traffic in Cybersecurity,” 2024.
- [6] J. Qu, X. Ma, and J. Li, “TrafficGPT: Breaking the Token Barrier for Efficient Long Traffic Analysis and Generation,” 2024.

Sesión de Investigación 2 - IA, modelos de lenguaje y aprendizaje

DP2Unlearning: An Efficient and Guaranteed Unlearning Framework for Large Language Models

(Extended Abstract of Published Paper [1])

Tamim Al Mahmud, Najeeb Jebreel, Josep Domingo-Ferrer, David Sánchez

Universitat Rovira i Virgili

Department of Computer Engineering and Mathematics

ComSCIAM-Center for Computational Science and Applied Mathematics

CYBERCAT-Center for Cybersecurity Research of Catalonia, Tarragona

{tamimal.mahmud, najeeb.jebreel, josep.domingo, david.sanchez}@urv.cat

Resumen—Large Language Models (LLMs) have transformed natural language processing, yet their capacity to store and reveal sensitive information raises privacy issues. Legal regulations such as the GDPR emphasize the Right to Be Forgotten (RTBF), which is difficult to implement with conventional LLMs without incurring expensive retraining. Approximate unlearning methods present a feasible solution but lack formal guarantees. We present DP2Unlearning, a new framework aimed at efficient, guaranteed unlearning in LLMs through ϵ -differential privacy (DP). By training LLMs on data that are protected for privacy and enabling targeted unlearning through fine-tuning, DP2Unlearning maintains model performance and ensures protection against disclosure on the data to be forgotten. Our results demonstrate that DP2Unlearning achieves unlearning performance comparable to full retraining at half the cost, surpassing existing unlearning approaches in both effectiveness and utility preservation.

Index Terms—Training data, Privacy risk, Right to be forgotten, Machine unlearning, Large language models

Tipo de contribución: Investigación ya publicada (límite 2 páginas)

I. INTRODUCTION

Large Language Models (LLMs) have become a cornerstone of modern artificial intelligence, powering many state-of-the-art applications. However, these models can memorize training data, which is prone to privacy risks during inference.

Privacy regulations such as the GDPR emphasize the need for efficient unlearning mechanisms. Specifically, the right to be forgotten (RTBF) requires the removal of personal data on request. Similarly, copyright laws require the removal of proprietary content from models.

The straightforward solution consists of retraining the model after removing the unwanted data. Although this guarantees that the target data are completely forgotten, retraining LLMs is expensive, making this approach impractical. Approximate unlearning methods, while more efficient, do not offer formal guarantees of forgetting, as they typically rely on heuristic techniques that adjust model parameters to suppress specific data after training.

This paper presents DP2Unlearning, a framework that combines differential privacy (DP) with model fine-tuning to achieve efficient and guaranteed unlearning in LLMs.

II. RELATED WORK

Unlearning methods can be classified into exact and approximate techniques. Exact unlearning ensures complete data

removal, but is too costly for LLMs. Researchers have worked to reduce the cost of exact unlearning methods, with proposals such as SISA [2] and APA [3], but these still incur significant costs and cause some loss of model utility.

On the other hand, approximate unlearning methods aim to modify trained models to forget specific data points *ex post*. These methods include gradient-based techniques [4], such as Gradient Ascent (GA), Gradient Difference (GD) and Kullback-Leibler (KL) minimization. However, approximate methods lack the guarantees offered by exact forgetting, which are a crucial requirement for privacy-sensitive applications.

III. METHODOLOGY

The DP2Unlearning framework is illustrated in Figure 1. The framework operates in three stages:




Figura 1. The DP2Unlearning Framework

Stage A – Unlearning-Ready Training: includes the training of a base model (BM_D^{DP}) that is protected from disclosure, with measures in place to prevent the release of any personal or copyright-protected information that might require unlearning. This can be achieved through two distinct methods:

1. DP-MLM: Training data are transformed using DP-MLM [5] (Differentially Private Masked Language Models). In DP-MLM, the enforcement of DP is achieved through the exponential mechanism, which probabilistically exchanges sensitive terms for others that are semantically similar. This approach maintains the integrity of the document structure while protecting privacy. A utility function $u(w, w')$ assesses the semantic similarity

between the original term w and its possible substitute w' using contextual embeddings and cosine similarity. The probability of substituting w with w' is expressed by $\Pr(w'|w) = \frac{\exp(u(w,w')\epsilon)}{\sum_{w'' \in V} \exp(u(w,w'')\epsilon)}$ where V represents the vocabulary and ϵ is the privacy parameter. DP-MLM targets the most sensitive components, such as noun phrases, without which sensitive information about data subjects cannot be disclosed [6]. The model is trained on these transformed data.

2. DP-SGD: Differentially Private Stochastic Gradient Descent applies differential privacy directly to the gradient update during model training by adding noise. DP-SGD modifies the standard SGD by incorporating gradient clipping, Gaussian noise injection, and gradient update. These procedures collectively ensure privacy by making individual data points indistinguishable while allowing the model to learn effectively.

Stage B – Pre-Unlearning Fine-Tuning: After the initial training, the resulting model BM_D^{DP} is fine-tuned on raw unprotected data to recover the utility lost due to the DP protection. Fine-tuning is more computationally efficient compared to retraining from scratch, enabling the model to restore its performance. After fine-tuning, the model obtained is deployed for production and is known as the full data model (FM_D^{DP}).

Stage C – Unlearning Execution: This step is activated whenever a forget request (D_f^i , where $i = 1, 2, 3 \dots, n$) arrives. The current model FM_D^{DP} is replaced with the base model BM_D^{DP} , which is then fine-tuned on the retained data D_r^i . This results in an unlearned model $UM_{D_f^i}$ that performs similarly to retraining on the retained data, while preserving ϵ -DP guarantees for the forgotten data, as these data points were only observed by the base model.

IV. RESULTS

We conducted experiments using Phi-1.5B and Llama2-7B models trained on the TOFU dataset, a benchmark designed to evaluate unlearning methods in LLMs. Our results show that DP2Unlearning provides performance comparable to retraining from scratch, but at a significantly lower computational cost. We also compared our method with approximate unlearning methods such as GA, GD, KL, and Preference Optimization (PO). Our framework outperformed these methods in terms of both model utility (MU) and forget quality (FQ).

Table I summarizes the results for a 5% forget ratio in the Phi and Llama2 models. RFS-R is the (extremely costly) retrain from scratch benchmark. Shaded methods are the best among the affordable ones (we did not use DP2U-SGD on Llama2 due to too high a cost).

In particular, the DP-MLM approach demonstrated strong effectiveness in safeguarding sensitive data during the training process while ensuring the model’s utility was largely preserved after unlearning requests. This makes DP2Unlearning a more efficient and reliable solution than approximate unlearning methods, which often suffer from poor forgetting quality.

V. CONCLUSIONS

We introduced DP2Unlearning, a privacy-preserving framework for efficient and guaranteed unlearning in LLMs. Using

Tabla I
FQ AND MU OF DIFFERENT UNLEARNING METHODS FOR PHI AND LLAMA2. RFS-R, traditional retraining from scratch on retained data SERVES AS THE BENCHMARK.

Model	Method	Epochs	MU ↑	FQ ↑	Runtime
Phi	RFS-R	10	0.5380	1.0000	32m42s
	GA	5	0.0000	0.0021	4m6s
	GD	5	0.1982	1.87E-09	5m39s
	KL	5	0.0000	0.0021	6m11s
	PO	5	0.5114	2.56E-14	7m17s
	DP2U-SGD	5	<u>0.5122</u>	0.9878	16m48s
	DP2U-MLM	5	0.5223	<u>0.9238</u>	16m43s
Llama2	RFS-R	6	0.5711	1.0000	1h36m24s
	GA	3	0.0000	2.61E-07	13m56s
	GD	3	0.3490	1.39E-11	15m4s
	KL	3	0.0000	<u>4.61E-07</u>	15m14s
	PO	3	<u>0.4950</u>	1.83E-19	16m40s
	DP2U-MLM	3	0.5320	0.8655	45m15s

ϵ -DP and DP-MLM, our framework ensures formal forgetting guarantees while maintaining model performance. Our experiments show that DP2Unlearning outperforms traditional retraining methods in computational efficiency and surpasses approximate unlearning techniques in both forgetting effectiveness and model utility.

This framework offers a scalable and cost-effective solution for organizations that need to comply with privacy regulations like the GDPR. Future work will extend this framework to support other data types, such as images, and explore alternative privacy models to further enhance the flexibility of DP2Unlearning.

ACKNOWLEDGMENTS

This work was supported by the Government of Catalonia (ICREA Acadèmia Prizes to J. Domingo-Ferrer and D. Sánchez) and MCIN/AEI under grant PID2024-157271NB-I00 “CLEARING-IT”.

REFERENCIAS

- [1] Al Mahmud, T., Jebreel, N., Domingo-Ferrer, J., and Sánchez, D., “DP2Unlearning: An efficient and guaranteed unlearning framework for LLMs”, en *Neural Networks*, vol. 192, pp. 107879, 2025.
- [2] Bourtole, L., Chandrasekaran, V., Choquette-Choo, C. A., Jia, H., Travers, A., Zhang, B., Lie, D., and Papernot, N., “Machine unlearning”, en *2021 IEEE Symposium on Security and Privacy (SP)*, pp. 141-159, 2021.
- [3] Hu, Z., Zhang, Y., Xiao, M., Wang, W., Feng, F., and He, X., “Exact and Efficient Unlearning for Large Language Model-based Recommendation”, en *Proceedings of ACM Conference*, 2024.
- [4] Maini, P., Feng, Z., Schwarzschild, A., Lipton, Z. C., and Kolter, J. Z., “TOFU: A task of fictitious unlearning for LLMs”, en *Secure and Trustworthy LLM Workshop, ICLR 2024*, 2024.
- [5] Meisenbacher, S., Chevli, M., Vladika, J., and Matthes, F., “DP-MLM: Differentially Private Text Rewriting Using Masked Language Models”, en *Findings of the Association for Computational Linguistics: ACL 2024*, Bangkok, Thailand, pp. 9314-9328, 2024.
- [6] Sánchez, D., and Batet, M., “ ϵ -sanitized: A privacy model for document redaction and sanitization”, en *Journal of the Association for Information Science and Technology*, vol. 67, no. 1, pp. 148-163, 2016.
- [7] Abadi, M., Chu, A., Goodfellow, I., McMahan, H. B., Mironov, I., Talwar, K., and Zhang, L., “Deep Learning with Differential Privacy”, en *Proceedings of the 2016 ACM SIGSAC Conference on Computer and Communications Security, CCS '16*, Vienna, Austria, pp. 308-318, 2016.

Breadth Over Depth: Why Domain Specialisation Without Multilingual Pretraining Fails for Bilingual Cybersecurity NER

Loya C. Haughton[†], Daniel Gregori-Guerra*, Eduardo Fidalgo[†], Victor González-Castro[†],
Laura Fernández-Robles[†], Alicia Martínez-Mendoza[†]

*School of Industrial, Informatics and Aerospace Engineering
Universidad de León, León, Spain
dgregg00@estudiantes.unileon.es

[†]Group for Vision and Intelligent Systems (GVIS)
I4 Institute, Universidad de León, León, Spain

{loya.haughton, eduardo.fidalgo, victor.gonzalez, l.fernandez, alicia.martinez}@unileon.es

Abstract—Cybersecurity incident reports are critical for threat intelligence, yet the sensitive data they contain restricts their sharing and reuse. This results in a scarcity of annotated datasets – particularly in non-English languages – which hinders the development of automated cyber incident analysis. To address this gap, we present annotated cyber incident dataset BITÁCORA (1,007 Spanish cyber incidents, 9,052 entity spans) and release CECILIA-NER-BILOU (880 English cyber incidents, 10,692 spans) as an evaluation resource derived from the existing CECILIA-10C-900 dataset. Using these resources, we evaluate multilingual and domain-specialised Named Entity Recognition (NER) models with 5-fold cross-validation. This reveals two key findings. First, domain-specialised models perform better on English than Spanish incidents, reflecting greater English-language training resources. Second, cross-lingual transfer is sharply asymmetric: English-to-Spanish degrades performance by 20.3%, while Spanish-to-English degrades by 61.6%. Together, these findings highlight the dominance of English in cybersecurity Natural Language Processing (NLP) within our experiments and suggests a pressing need for Spanish-language corpora to support multilingual cyber threat intelligence.

Index Terms—Named Entity Recognition (NER), Cross-lingual transfer learning, Natural Language Processing (NLP), cybersecurity, sensitive data, threat intelligence, model evaluation

Type of Contribution: *Investigación original*

I. INTRODUCTION

In recent years, cyber incident management has seen a sustained increase in the volume of textual information handled by security teams, such as technical reports, alert descriptions, tickets, vendor bulletins, social media posts, and threat intelligence [1]. Much of this content is in natural language, with different levels of detail, styles and noise. This makes analyses like evidence correlation, incident classification, and report preparation challenging [2], [3], [4].

Named Entity Recognition (NER) is a core task in Natural Language Processing (NLP) that focuses on extracting named entities from unstructured text. In the cybersecurity domain, NER enables analysts to systematically identify relevant signals such as personal data (people, organisations), products, vulnerabilities, and technical indicators. This converts raw text into usable, structured information and enables downstream automation. However, the cybersecurity domain introduces specific challenges such as non-standardised formats, ambiguous

acronyms, alphanumeric strings, spelling variations, and long or highly technical entities that do not appear with the same frequency in general corpora [3], [5], [6]. These challenges are compounded by the multilingual nature of the field.

Since cyber incidents occur in all languages, tools for extracting named entities – such as personal data or technical details – should be multilingual. However, cybersecurity terminology is coined almost exclusively in English and then translated into other languages with varying degrees of adaptation. This transfer often results in metaphorical loss (e.g., in Spanish, phishing may become *captación ilegítima de datos confidenciales*) in some contexts, as well as in direct borrowings that lack contextual transparency and high synonymic variation. These properties make cybersecurity NER in non-English languages a distinct challenge [7]. Consequently, most of the existing work focuses on English corpora, leaving the cross-lingual dimension underexplored. The scarcity of comparably annotated resources, especially outside the English language, further complicates training robust models and evaluating them homogeneously [3], [8], [9].

One downstream application where NER quality may be critical is pseudonymisation. This technique processes personal data so it cannot be linked to an individual without additional information; with the goal of balancing data utility and privacy [10]. Cyber incident reports, handled by Cybersecurity Emergency Response Teams (CERTs) / Cybersecurity Incident Response Teams (CSIRTS), frequently contain personal data and organisationally sensitive information whose exposure poses confidentiality risks. Pseudonymisation offers a path forward for mitigating these risk and has been extensively explored in clinical and legal domains [11], [12]. In these domains, pseudonymisation typically works in two stages: first, entities which contain sensitive data are detected, then they are replaced with pseudonyms. Thus, the quality of the downstream pseudonymisation is fundamentally bounded by the recall of the upstream NER [13], [14].

Accurate multilingual entity recognition is therefore an important component of this pipeline. Robust NER supports organisations such as international CERTs and CSIRTS to share anonymised or pseudonymised incident reports. In turn, this may enable machine learning models to be trained on realistic

data for tasks such as automatic incident classification using a national cyber incident taxonomy [4]. Yet NER-driven pseudonymisation for this domain has received little attention despite its relevance to enabling safe data sharing for research and model training.

Therefore, research that combines bilingual NER evaluation with pseudonymisation specifically for cybersecurity incident texts is underexplored. Moreover, it remains untested whether domain-specialised NER models trained on English generalise to Spanish for subsequent pseudonymisation of cyber incident texts, despite it being an operational reality across Spanish-speaking countries.

In this context, this body of work evaluates NER models on cyber incident texts in both English and Spanish. More specifically, it makes the following contributions:

- An annotated cyber incident NER dataset: BITÁCORA which contains 1,007 Spanish incidents. As an evaluation artefact, we also release CECILIA-NER-BILOU, an annotated version of the 880 English incidents contained in the CECILIA-10C-900 corpus [4]). Both were annotated using entity types relevant to sensitive data identification to support reproducibility and future NER evaluation in the cybersecurity domain.
- A comparative evaluation of two multilingual generalist baselines (XML-ROBERTa [15] and multilingual BERT [16]) against a cybersecurity domain-adapted model (SECUREBERT-2.0 [17]) to determine which model identifies named entities most effectively across both languages. We additionally illustrate a pseudonymisation module demonstrating the practical utility of trained NER models for de-identification of cyber incident reports.

II. RELATED WORK

This section reviews the literature most relevant to our work. First, we examine existing NER approaches in the cybersecurity domain in Section II-A. We then discuss the challenges of cross-lingual and multilingual NER, with a focus on English–Spanish transfer (Section II-B). Finally, we review pseudonymisation techniques and their dependence on upstream entity recognition (Section II-C).

A. NER in Cybersecurity

Applying NER to cybersecurity requires extracting entity types that differ substantially from general-purpose NER: malware families, vulnerability identifiers, software tools, indicators of compromise and version strings. These texts exhibit mixed conventions — alphanumeric tokens, non-standardised abbreviations, and terms with contextual polysemy — which cause models trained on news or encyclopedic corpora to underperform on domain-specific patterns [3], [5].

Two complementary strategies have emerged. First, hybrid approaches combine rule-based extraction for structured patterns (e.g., CVE identifiers, IP addresses) with neural models for context-dependent entities. CyNER [18] exemplifies this design, integrating heuristic extractors, domain-tuned transformers and generic NER with explicit overlap resolution. The second strategy is domain-specific pretraining, that is, continued training on in-domain text to adapt a general purpose model to a specialised function. SecureBERT [19] was pretrained on cybersecurity corpora to capture technical vocabulary, and

SecureBERT 2.0 [17] extends this with a longer context window and pretraining on over 13.6 billion tokens, aiming to mitigate errors from homographs and terms poorly represented in general corpora.

Despite these advances, standardisation remains limited. Datasets vary in entity coverage, annotation criteria, and construction methodology, making cross-study comparison difficult [3], [8], [9]. This problem is compounded by the linguistic dimension. Cybersecurity terminology is coined almost exclusively in English and is translated into other languages with varying degrees of adaptation: metaphorical terms may lose transparency (e.g., phishing becoming *captación ilegítima de datos confidenciales*), borrowings coexist with descriptive paraphrases, and a single English term may map to multiple target-language synonyms. For example, Maroto documents up to seven Spanish equivalents for hoax alone [7]. These properties make cybersecurity NER in non-English languages a distinct challenge, yet annotated resources outside English are scarce.

B. Multilingual Models and Cross-lingual Transfer

Multilingual transformer models provide a shared representational space for NER across languages without requiring parallel corpora. mBERT [16], [20], pretrained on Wikipedia in 104 languages with a shared WordPiece vocabulary, established the viability of zero-shot cross-lingual transfer for sequence labelling. XML-ROBERTa [15], pretrained on filtered CommonCrawl data in 100 languages with dynamic masking, consistently outperforms mBERT in cross-lingual NER benchmarks [21]. However, both models are subject to the “curse of multilinguality”: shared capacity across many languages can degrade per-language performance, particularly for underrepresented languages or specialised domains [15].

When annotated data in the target language-domain pair is scarce, approaches like leveraging class-name semantics [22] and self-training with unlabelled corpora [23] have shown improvements under limited supervision. However, in the cybersecurity domain, where expert annotation is costly and datasets are small, annotation efficiency is a practical concern [24]. This makes the question of whether multilingual models can compensate for domain data scarcity — or whether English-only domain models generalise across languages — directly relevant.

C. Pseudonymisation techniques and their dependence on upstream entity recognition

Pseudonymisation pipelines in the clinical and legal domain typically follow a two-stage architecture: a NER model detects protected information, and a replacement module substitutes it with realistic surrogates or removes it [11], [12]. In both domains, studies consistently show that downstream pseudonymisation quality is bounded by the recall of the upstream NER [13], [14].

In cybersecurity, the need for such pipelines likely stems from the challenge of sharing threat intelligence. Collaborative exchange of incident data is widely recognised as essential for effective detection and response [25], [26], yet organisations remain reluctant to share due to concerns over confidentiality, data sovereignty, and regulatory compliance [27], [28]. Data sanitisation has been proposed to balance this tension between

sharing utility and leakage risk [26], and the European Union Agency for Cybersecurity (ENISA) has highlighted pseudonymisation as a key technical measure in this context [10]. However, existing sanitisation work in cybersecurity has focused on format-specific approaches for structured data, such as IP addresses and packet traces [26], rather than NER-driven pseudonymisation of free-text incident reports. This leaves an open question: whether NER models — particularly those evaluated in Sections II-A and II-B — can serve as a reliable upstream component for pseudonymising multilingual cyber incident texts.

III. DATASET CONSTRUCTION: BITÁCORA, AND CECILIA-NER-BILOU

A. Cyber Incident Report Collection

In cybersecurity, annotated, up-to-date and publicly available cyber incident datasets are scarce. Existing cyber incident NER datasets are predominantly English-language and vary widely in entity coverage and annotation criteria [3], making direct bilingual comparison impractical. To address this, two datasets were constructed under a shared annotation scheme: BITÁCORA (1,007 Spanish incidents) and CECILIA-NER-BILOU (880 English incidents).

Firstly, BITÁCORA was extracted from two sources: official cybersecurity alert bulletins from Paraguay’s Ministry of Information and Communication Technologies (MITIC) [29] and publications from the Spanish National Cybersecurity Institute’s (INCIBE’s) Cybersecurity Blog [30]. This approach made it possible to gather texts with institutional writing and an operational orientation, close to the documents handled by response teams, while at the same time broadening the variety of styles within a common thematic framework.

The English cyber incidents were sourced from the CECILIA-10C-900 dataset [4]. This dataset contains 880 unique cyber incidents extracted from five cyber incident repositories, spanning ten incident classes. Given the diversity of incidents, it was therefore selected to enable controlled comparison with the 1007 incidents of its Spanish counterpart, BITÁCORA. Both datasets were then cleaned and normalised, along with encoding standardisation and whitespace regularisation.

B. Entity Identification

Both datasets were annotated using a common set of entities (Table I), selected to capture both personal data and organisationally sensitive data. The annotation process is described in Section III-C.

To represent entity boundaries, the BILOU (also called BIOLU) scheme (Begin-Inside-Last-Unit-Outside) was used, which explicitly encodes entity start and end points, as well as single-token mentions [31]. BILOU was chosen because NER performance is especially sensitive to exact span delimitation, and having explicit closing marks and unit entities helps reduce ambiguities that are frequent in short, technical, or irregularly structured entities [31], [32]. Furthermore, choosing a popular labelling scheme promotes reproducibility because NER dataset annotation is not standardised [33].

The datasets were originally annotated with 18 entity types (Table I). To enable consistent evaluation across both corpora, a two-step consolidation was applied before training.

1) Merged semantically related categories:

GPE_Location and Location were unified under a single GPE_Location class, since cybersecurity incident texts rarely distinguish between geopolitical and physical geographic mentions; similarly, Quantities, Numbers_C (cardinal) and Numbers_O (ordinal) were collapsed into a single numeric class, as their boundary patterns and contextual cues overlap substantially in this domain.

2) *Removed low frequency categories:* The three least frequent entity types in each dataset were removed. Facilities, Language, and Art were dropped from BITÁCORA, while Events, Language, Art and Law were dropped from CECILIA-NER-BILOU. In all cases, the token counts were insufficient for models to learn meaningful representations across stratified five-fold evaluation, described in Section V-A. After consolidation, the effective training inventory comprised of 12 entities for BITÁCORA, and 11 entities for CECILIA-NER-BILOU. Details of this consolidation are shown in Table I.

C. Dataset Annotation

To promote efficient resource use, annotation was done in two phases: a semi-automatic pre-annotation followed by a manual, human-led review. Pre-annotation was performed in *Label Studio* [34] using a prediction backend tailored to the project’s workflow. For the English set, the *gliner_medium-v2.1* model was used, while for Spanish, *gliner_multi-v2.1* model was employed [35].

Both models were configured with a flat labelling scheme without BILOU encoding, so their predictions were projected onto the BILOU format during import into *Label Studio*. Notably, this pre-annotation served only as an initial proposal. Subsequently, a single annotator reviewed every span, correcting boundaries, reassigning entity types, removing false positives, and adding missed mentions. This workflow reduced annotation time compared to fully manual labelling while keeping the human annotator as the final authority on all decisions. This design choice is further discussed as a limitation in Section VII.

Next, to enforce annotation consistency in real time, a webhook was also integrated into *Label Studio*. The webhook automatically validated each saved annotation against the BILOU syntax. These checks included:

- automatically normalising tag sequences when the annotator modified spans, in order to reduce the risk of boundary errors during manual editing.
- realigning misplaced boundaries to token edges,
- removing duplicate overlapping spans, and
- correcting malformed tag sequences (e.g., orphaned I- tags lacking a preceding B-, or missing L- closures).

This automated quality layer was most important during the initial manual phase of approximately 150 texts, where annotator criteria were still being calibrated and inconsistencies were most likely.

This resulted in two annotated datasets in the cyber incident domain: BITÁCORA, in Spanish, and CECILIA-NER-BILOU, in English. Both datasets are converted from their annotation format to a homogeneous representation by normalising label format and consolidating categories with conceptual overlap




Figure 1. Overview of the experimental design. Three base models (multilingual BERT, XML-RoBERTa, and SECUREBERT-2.0) are fine-tuned on two annotated corpora (BITÁCORA in Spanish and CECILIA-NER-BILOU in English), yielding six model variants. These are evaluated under eight conditions combining in-language and cross-lingual test settings.

Table I
ENTITY CATEGORIES, DESCRIPTIONS, AND CONSOLIDATION ACTIONS. POST-CONSOLIDATION INVENTORIES COMPRISE 12 CLASSES FOR BITÁCORA AND 11 CLASSES FOR CECILIA-NER-BILOU. IN THE ACTION COLUMN, REMOVED^B AND REMOVED^C INDICATE THAT THE CATEGORY WAS REMOVED FROM BITÁCORA OR CECILIA-NER-BILOU, RESPECTIVELY, WHILE → TARGETCATEGORY INDICATES THAT THE ROW’S CATEGORY WAS MERGED INTO TARGETCATEGORY.

Entity Category	Description	Action
Art	Titles of creative works (books, movies, songs)	Removed ^{B, C}
Date	Specific calendar dates or years	Retained
Events	Named occurrences (wars, festivals)	Removed ^C
Facilities	Buildings, airports, highways, bridges	Removed ^B
GPE_Location	Geopolitical entities and geographical features	Retained
Group	Groups not classified as NORP or Organization	Retained
Language	Named human languages	Removed ^{B, C}
Law	Named legal documents, acts, regulations	Removed ^C
Location	Geographical features (mountains, rivers)	→ GPE_Location
Money	Monetary values including currencies	Retained
Norp	Nationalities, religious or political groups	Retained
Numbers_C	Cardinal numeric values	→ Numbers
Numbers_O	Ordinal numbers (first, 2nd, third)	→ Numbers
Organization	Companies, agencies, institutions	Retained
Person	Names of individual people	Retained
Products	Vehicles, software, consumer products	Retained
Quantities	Measurements, weights, distances	→ Numbers
Time	Times of day, durations, clock times	Retained

to reduce dispersion and gain statistical support. See Section III-B for more details.

IV. EXPERIMENTAL SETUP

Figure 1 provides an overview of the methodology pipeline. Two multilingual generalist transformer models were selected: mBERT (base) and XLM-RoBERTa (base). These served as base-lines for quantifying the contribution of domain specialisation. Since both models explicitly cover English and Spanish in a single checkpoint, this allows for training and evaluation under a common framework. The best-performing model from this first phase of evaluation is used for multilingual evaluation.

SecureBERT 2.0 was incorporated as a domain-specialised model. This model represents the most recent and largest publicly available encoder pretrained on cybersecurity text, with over 13.6 billion pretraining text tokens and an extended context window. At the time of experimentation, no

other domain-adapted encoder offered comparable scale or recency. SecureBERT 2.0 also adopts a long-sequence-oriented architecture and expands the input size beyond the typical BERT-base limit, allowing dependencies to be retained over greater distances. A domain-specific model was integrated into the experimental design, as cybersecurity texts contain a plethora of technical artefacts and conventions that are not well represented in generalist corpora. Consequently, a model specifically pre-trained on cybersecurity language has an advantage in assigning contextual meaning to that vocabulary. For CECILIA-NER-BILOU, a data augmentation strategy was applied to address class imbalance: entities belonging to low-frequency categories were replaced with alternative mentions of the same type. Thus, increasing minority-class representation in the training folds while leaving evaluation folds untouched. This step was not necessary for BITÁCORA, as its most underrepresented categories had already been removed during

frequency-based filtering.

Micro- and macro- F1 scores, recall and precision were used to evaluate the models, since it is the standard for entity extraction task evaluation and will aid comparability to other literature.

A. Pseudonymisation Module

The pseudonymisation module illustrates the downstream applicability of trained NER models for deidentification of CTI. This post-detection stage for entities and sensitive data, transforms text to reduce information exposure while maintaining part of its usefulness for subsequent analyses. Its input is the set of entities detected in each document, and its output is transformed text where identified mentions are substituted according to a selected pseudonymisation technique.

V. EXPERIMENTATION AND RESULTS

A. Experimental Settings

Evaluation of the NER models was performed using document-level K -fold cross-validation, with $K=5$. Stratification was performed by counting entity-initiating labels (B- and U-) per category and per document, and distributing documents across folds so that each fold contained approximately 20% of spans for each category. This was done instead of stratifying by class at the instance or token level to improve the reliability of the evaluation, ensuring that no fold was disproportionately enriched or depleted for any entity category.

Training was conducted using the AdamW optimiser with weight decay, learning rate scheduling, and proportional warmup. Within each training fold, 15% was held out as a validation set for early stopping. This enabled monitoring validation performance. The hyperparameters are detailed in Table II.

B. Baseline Results

Table III summarises monolingual performance across all models and datasets. Among the non-domain specialised baselines in both BITÁCORA and CECILIA-NER-BILOU, XML-ROBERTa achieves the highest Micro-F1 score (0.8203 and 0.7800, respectively), with mBERT trailing in each case. In BITÁCORA, the difference is driven primarily by precision rather than recall, which remains comparable between the two models. In practical terms, mBERT does not miss more entities, instead it produces more false positives. In CECILIA-NER-BILOU, the gap between XML-ROBERTa and mBERT is generally narrower. Both models frequently mislabel Facilities entities as Organization and vice versa. This persists across both baselines, consistent with the semantic overlap between building names and institution names.

Across both datasets, a consistent pattern emerges in per-category recall. Entity types with stable patterns and

high frequency, such as Norp, GPE_Location, and Date, consistently achieve recall above 0.90. Conversely, categories with lower support or greater semantic ambiguity, such as Products, Time, and Events, fall below 0.75. In these weaker categories, the dominant error is not misclassification into another entity type but absorption into *O*, which means that the model fails to detect the entity.

Table III
MONOLINGUAL NER EVALUATION. BEST RESULT PER DATASET IN **BOLD**.

Dataset	Model	Micro-F1	Macro-F1	Prec.	Recall
BITÁCORA	XML-ROBERTa	0.8203	0.7523	0.7729	0.8744
	mBERT	0.8049	0.7210	0.7460	0.8739
	SecureBERT 2.0	0.5309	0.3807	0.4332	0.6868
CECILIA-NER-BILOU	XML-ROBERTa	0.7800	0.7023	0.7250	0.8441
	mBERT	0.7712	0.6872	0.7203	0.8296
	SecureBERT 2.0	0.7919	0.6623	0.6754	0.7722

C. Comparison with SecureBERT 2.0

SecureBERT 2.0 is the only model to outperform XML-ROBERTa, achieving the highest Micro-F1 on CECILIA-NER-BILOU (0.7919 vs. 0.7800). This suggests that domain pre-training may provide a genuine advantage when the model operates in its pretraining language. However, the gap between its Micro-F1 and Macro-F1 (0.7919 vs. 0.6623) is wider than XML-ROBERTa's (0.7800 vs. 0.7023), indicating that SecureBERT's advantage is concentrated in high-frequency categories while minority classes like Products (0.19 recall) and Facilities (0.25) collapse even in English.

On Spanish data, SecureBERT 2.0 collapses to a Micro-F1 of 0.5309. Figure 2 shows the confusion matrix: Events (0.04 recall), Law (0.04), and Time (0.16) suffer near-total failure, with the dominant pattern being massive absorption into *O* across almost all categories. Its performance is anchored mostly on entity types whose surface forms are similar across languages: GPE_Location (0.81), Date (0.78) and Numeric (0.78). The model, lacking any Spanish pretraining, defaults to not labelling rather than risking an incorrect class. Additionally, Events and Law show notable misclassification toward Organization (0.25 and 0.28, respectively), suggesting the model relies on its most confident English-trained category when uncertain.

D. Language Transfer Evaluation

Following the design in Section III-D, only XML-ROBERTa — the best-performing multilingual model in the monolingual phase — was carried forward for cross-lingual evaluation. SecureBERT 2.0 was excluded as it lacks Spanish pretraining, and mBERT was omitted as the weaker multilingual baseline.

Table IV quantifies what happens when the training and deployment languages diverge. English-trained XML-ROBERTa tested on Spanish retains a Micro-F1 of 0.6216 — a 20.3% degradation — with recall remaining relatively high (0.7613). However, precision falls sharply (0.5252), indicating systematic over-detection. The reverse direction exhibits more severe degradation. Spanish-trained, English-tested performance falls to 0.3153, a 61.6% degradation, with both precision and recall

Table II
TRAINING HYPERPARAMETERS PER MODEL AND DATASET.

Dataset	Model	LR	Epochs	WD	Drop.	WR	ES _{pat}	ES _{thr}
BITÁCORA	XML-ROBERTa	3e-5	20	0.01	0.1	0.1	2	0.001
	mBERT	2e-5	20	0.1	0.2	0.1	2	0.001
	SecureBERT 2.0	1e-5	15	0.001	0.05	0.05	3	0.0
CECILIA-NER-BILOU	XML-ROBERTa	3e-5	12	0.01	0.1	0.1	2	0.001
	mBERT	2e-5	20	0.02	0.2	0.02	2	0.005
	SecureBERT 2.0	1e-5	20	0.1	0.3	0.2	3	0.002

WD = Weight Decay; Drop. = Dropout; WR = Warmup Ratio; ES_{pat} = Early Stopping Patience; ES_{thr} = Early Stopping Threshold.

Formato LaTeX/confusion_matrix_securebert_bitacora.png

Figure 2. Normalised confusion matrix for SECUREBERT-2.0 fine-tuned and evaluated on BITÁCORA. The model performs well on more well-represented entity types (e.g., Date, GPE_Location, Number (referred to here as Numeric), Organization) but struggles with domain-specific and low-frequency types (e.g., Events, Law, Time), which are predominantly misclassified as O (outside).

collapsing. The model trained on Spanish massively over-detects Organization, Person, Group and Products in English, suggesting that contextual cues which may be useful in Spanish do not transfer as valid discriminative signals to English text.

This asymmetry is not uniform across entity types. Person and GPE_Location transfer robustly from English to Spanish (F1-Score = 0.84), consistent with proper nouns sharing surface forms across languages. DATE remains stable in both directions, reflecting the regularity of temporal patterns. In contrast, Products and Numeric (F1-Score = 0.46) degrade substantially in the EN→ES direction, and collapse further in the reverse. The practical implication is that off-the-shelf English cybersecurity NER models may not reliably substitute for in-language training data.

The asymmetry likely stems from two compounding factors. First, XML-RoBERTa’s pretraining corpus (CommonCrawl) contains substantially more English than Spanish data, meaning its English representations are richer and more robust as a transfer target. Second, Spanish cybersecurity texts frequently borrow English terminology directly — product names, CVE identifiers, malware families — making English-trained entity patterns partially recognisable in Spanish surface forms. The reverse does not hold: Spanish-specific syntactic constructions and paraphrases of cybersecurity concepts do not appear in English incident texts, so Spanish-trained contextual cues find

no equivalent signal to latch onto, causing the severe precision collapse observed.

Table IV
EFFECT OF LANGUAGE MISMATCH ON NER PERFORMANCE
(XML-ROBERTA). MATCHED ROWS REPRODUCED FROM TABLE III.

	Scenario	Micro-F1	Prec.	Recall	Δ^*
Match	Train EN → Test EN	0.7800	0.7250	0.8441	—
	Train ES → Test ES	0.8203	0.7729	0.8744	—
Mism.	Train EN → Test ES	0.6216	0.5252	0.7613	−20.3%
	Train ES → Test EN	0.3153	0.2379	0.4673	−61.6%

*Relative Micro-F1 degradation: EN→ES vs. EN→EN; ES→EN vs. ES→ES.

E. Pseudonymisation Module

As a downstream application of the NER pipeline, the pseudonymisation module described in Section III-E was applied to both datasets using the best-performing XML-RoBERTa checkpoint. Three techniques were employed: contextual synthetic generation, partial masking, and reversible deterministic hashing, illustrated in Table V on a fictitious yet representative cyber incident written in Spanish.

This demonstration also highlights the pipeline’s relevance to the Secure Interactive Environments for SensiTive data Analytics (SIESTA) project, where pseudonymisation of cyber

Table V
PSEUDONYMISATION TECHNIQUES APPLIED TO A SPANISH CYBER INCIDENT TEXT. DETECTED ENTITIES ARE UNDERLINED IN THE ORIGINAL.

Technique	Text
Original	El día <u>15 de marzo de 2024</u> , la empresa <u>Microsoft Corporation</u> comunicó que <u>Juan García López</u> , director de seguridad, detectó un ciberataque proveniente de <u>Rusia</u> .
Synthetic generation	El día <u>11/06/2024</u> , la empresa <u>CloudSecure Inc</u> comunicó que <u>Narciso Tormo-Ayuso</u> , director de seguridad, detectó un ciberataque proveniente de <u>Valencia</u> .
Partial masking	El día ** de ***** de **24, la empresa M***** C***** comunicó que J*** G***** L****, director de seguridad, detectó un ciberataque proveniente de R*****.
Deterministic hashing	El día DAT_4c3c8a24, la empresa ORG_08dbf8 comunicó que PER_2ec454, director de seguridad, detectó un ciberataque proveniente de LOC_56b9d7.

incident reports is a key enabler for secure data sharing between CERTs and CSIRTs. Since the effectiveness of all three techniques is bounded by upstream NER recall, the bilingual evaluation presented earlier directly informs the viability of automated pseudonymisation for Spanish cyber incident texts.

Accordingly, this section does not evaluate pseudonymisation performance; rather, it illustrates how the trained NER models can be applied to de-identification as a practical downstream task. Formal evaluation of re-identification risk and utility preservation remains beyond the scope of this work.

VI. LIMITATIONS

The main limitations of this work are the use of a single annotator without inter-annotator agreement measurement, class imbalance in low-frequency entity categories, and the absence of a formal evaluation of the pseudonymisation module. We also acknowledge that evaluating a single domain-specialised model limits the generalisability of our findings regarding domain specialisation. Future work will focus on expanding BITÁCORA with greater source diversity to reinforce minority classes and increase the corpora size, conducting multi-annotator validation, expanding the experimentation to include LLM evaluation and other domain specialised models, as well as evaluating re-identification risk and the preservation of utility in the pseudonymised outputs.

VII. CONCLUSIONS

This work presents BITÁCORA, an annotated Spanish-language NER dataset for cybersecurity incident texts. As an evaluation resource, we also release CECILIA-NER-BILOU—an annotated version of CECILIA-10C-900—under the same BILOU scheme and entity inventory to enable controlled bilingual comparison.

Three findings emerge with practical implications. First, in our experiments generalist multilingual models — particularly XML-ROBERTa (micro-F1 of 0.8203 on BITÁCORA, 0.7800 on CECILIA-NER-BILOU) — offer the most robust performance across both languages, which may make them the recommended baseline for organisations processing cyber incident texts in Spanish.

Second, whilst the substandard Spanish performance of SecureBERT 2.0 is expected given its English-only pretraining, the scale of the collapse is notable. Monolingual English models without domain specialisation appear to retain some incidental cross-lingual competence, possibly due to shared vocabulary. However, on BITÁCORA, SecureBERT scores below

mBERT in micro-F1 (0.5309 vs. 0.8049), despite the latter lacking any domain specialisation. This gap suggests that domain-specific pretraining may actively overwrite residual cross-lingual transfer rather than merely failing to extend it. Therefore, practitioners may wish to validate domain-specialised models trained exclusively on English before deploying them in multilingual cybersecurity settings.

Thirdly, our results suggest that cross-lingual transfer is markedly asymmetric: English-to-Spanish retains partial utility (micro-F1 score = 0.6216, 20% degradation) while Spanish-to-English degrades severely (0.3153, 62% degradation). This asymmetry likely stems from the prevalence of English in pretraining corpora and the partial transferability of English cybersecurity terms into Spanish. These findings may underscore the importance of in-language annotated data and could indicate that training data volume and pretraining representation quality drive transfer success.

These results may also carry a practical message for the Spanish-speaking cybersecurity community: when no in-language training data is available, multilingual models trained on English data offer a starting point for Spanish NER, but dedicated Spanish annotation yields substantial gains. BITÁCORA provides that starting point, reducing the gap in Spanish resources for the cybersecurity domain. Since no multilingual cybersecurity-adapted model currently exists, applying domain-adaptive pretraining to a multilingual model may be considered as a natural next step.

ACKNOWLEDGMENT

This work is funded by the European Union through the Secure Interactive Environments for SensiTive data Analytics (SIESTA) Project (Horizon Europe) under grant number 101131957. The authors also acknowledge the tireless work of the GVIS Labelling Team in annotating the datasets.

REFERENCES

- [1] M. Abdullah, M. M. Nawaz, B. Saleem, M. Zahra, E. b. Ashfaq, and Z. Muhammad, “Evolution Cybercrime—Key Trends, Cybersecurity Threats, and Mitigation Strategies from Historical Data,” *Analytics*, vol. 4, no. 3, p. 25, Sep. 2025. [Online]. Available: <https://www.mdpi.com/2813-2203/4/3/25>
- [2] J. Li, A. Sun, J. Han, and C. Li, “A survey on deep learning for named entity recognition,” *IEEE transactions on knowledge and data engineering*, vol. 34, no. 1, pp. 50–70, 2020. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/9039685/>
- [3] C. Gao, X. Zhang, M. Han, and H. Liu, “A review on cyber security named entity recognition,” *Frontiers of Information Technology & Electronic Engineering*, vol. 22, no. 9, pp. 1153–1168, Sep. 2021. [Online]. Available: <https://doi.org/10.1631/FITEE.2000286>

- [4] J. J. D. Sotes, A. M. Mendoza, A. C. Vasco, E. F. Fernandez, and E. A. Gutierrez, "CECILIA: Enhancing CSIRT Effectiveness with Transformer-Based Cyber Incident Classification," in *Proceedings of the First International Conference on Natural Language Processing and Artificial Intelligence for Cyber Security*, R. Mitkov, S. Ezzini, T. Ranasinghe, I. Ezeani, N. Khallaf, C. Acarturk, M. Bradbury, M. El-Haj, and P. Rayson, Eds. Lancaster, UK: International Conference on Natural Language Processing and Artificial Intelligence for Cyber Security, Jul. 2024, pp. 186–195.
- [5] S. Dasgupta, A. Piplai, A. Kotal, and A. Joshi, "A comparative study of deep learning based named entity recognition algorithms for cybersecurity," in *2020 IEEE International Conference on Big Data (Big Data)*. IEEE, 2020, pp. 2596–2604.
- [6] Y. Zhang, J. Liu, X. Zhong, and L. Wu, "SecLMNER: A framework for enhanced named entity recognition in multi-source cybersecurity data using large language models," *Expert Systems with Applications*, vol. 271, p. 126651, May 2025. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0957417425002738>
- [7] N. Maroto, *11 The terminology of cybersecurity and its metaphors*. De Gruyter Mouton, Jun. 2024, pp. 261–282. [Online]. Available: <https://www.degruyterbrill.com/document/doi/10.1515/9783111073149-012/>
- [8] A. Alshaibi, M. Al-Ani, A. Al-Azzawi, A. Konev, and A. Shelupanov, "The comparison of cybersecurity datasets," *Data*, vol. 7, no. 2, p. 22, 2022. [Online]. Available: <https://www.mdpi.com/2306-5729/7/2/22>
- [9] O. Yavanoglu and M. Aydos, "A review on cyber security datasets for machine learning algorithms," in *2017 IEEE international conference on big data (big data)*. IEEE, 2017, pp. 2186–2193. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/8258167/>
- [10] European Network and Information Security Agency., *Pseudonymisation techniques and best practices: recommendations on shaping technology according to data protection and privacy provisions*. LU: Publications Office, 2019. [Online]. Available: <https://data.europa.eu/doi/10.2824/247711>
- [11] H. Abu Attieh, A. Müller, F. N. Wirth, and F. Prasser, "Pseudonymization tools for medical research: A systematic review," *BMC Medical Informatics and Decision Making*, vol. 25, no. 1, p. 128, Mar. 2025.
- [12] L. A. Cabrera-Diego and A. Gheewala, "PSILENCE: A Pseudonymization Tool for International Law," in *Proceedings of the Workshop on Computational Approaches to Language Data Pseudonymization (CALD-pseudo 2024)*, E. Volodina, D. Alfter, S. Dobnik, T. Lindström Tiedemann, R. Muñoz Sánchez, M. I. Szawerna, and X.-S. Vu, Eds. St. Julian's, Malta: Association for Computational Linguistics, Mar. 2024, pp. 25–36.
- [13] O. de Gibert, A. García-Pablos, M. Cuadros, and M. Melero, "Spanish datasets for sensitive entity detection in the legal domain," in *Proceedings of the thirteenth language resources and evaluation conference*, 2022, pp. 3751–3760. [Online]. Available: <https://aclanthology.org/2022.lrec-1.400/>
- [14] P. López-Ubeda, M. C. Díaz-Galiano, L. A. U. López, and M. T. M. Valdivia, "Anonymization of Clinical Reports in Spanish: a Hybrid Method Based on Machine Learning and Rules," in *Proceedings of the Iberian Languages Evaluation Forum (IberLEF 2019)*, 2019, pp. 687–695. [Online]. Available: https://www.academia.edu/download/86706569/MEDDOCAN_paper_7.pdf
- [15] A. Conneau, K. Khandelwal, N. Goyal, V. Chaudhary, G. Wenzek, F. Guzmán, E. Grave, M. Ott, L. Zettlemoyer, and V. Stoyanov, "Unsupervised cross-lingual representation learning at scale," in *Proceedings of the 58th annual meeting of the association for computational linguistics*, 2020, pp. 8440–8451. [Online]. Available: <https://aclanthology.org/2020.acl-main.747/>
- [16] J. Devlin, M.-W. Chang, K. Lee, and K. Toutanova, "BERT: Pre-training of deep bidirectional transformers for language understanding," in *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies (NAACL-HLT)*, 2019, pp. 4171–4186.
- [17] E. Aghaei, S. Jain, P. Arun, and A. Sambamoorthy, "SecureBERT 2.0: Advanced Language Model for Cybersecurity Intelligence," Oct. 2025, arXiv:2510.00240 [cs]. [Online]. Available: <http://arxiv.org/abs/2510.00240>
- [18] M. T. Alam, D. Bhusal, Y. Park, and N. Rastogi, "CyNER: A Python Library for Cybersecurity Named Entity Recognition," Apr. 2022, arXiv:2204.05754 [cs]. [Online]. Available: <http://arxiv.org/abs/2204.05754>
- [19] E. Aghaei, X. Niu, W. Shadid, and E. Al-Shaer, "SecureBERT: A Domain-Specific Language Model for Cybersecurity," in *Security and Privacy in Communication Networks*, F. Li, K. Liang, Z. Lin, and S. K. Katsikas, Eds. Cham: Springer Nature Switzerland, 2023, vol. 462, pp. 39–56, series Title: Lecture Notes of the Institute for Computer Sciences, Social Informatics and Telecommunications Engineering. [Online]. Available: https://link.springer.com/10.1007/978-3-031-25538-0_3
- [20] T. Pires, E. Schlinger, and D. Garrette, "How multilingual is multilingual BERT?" in *Proceedings of the 57th annual meeting of the association for computational linguistics*, 2019, pp. 4996–5001. [Online]. Available: <https://aclanthology.org/P19-1493/>
- [21] M. Ulčar, A. Žagar, C. S. Armendariz, A. Repar, S. Pollak, M. Purver, and M. Robnik-Šikonja, "Mono-and cross-lingual evaluation of representation language models on less-resourced languages," *Computer Speech & Language*, vol. 95, p. 101852, 2026. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0885230825000774>
- [22] J. Ma, M. Ballesteros, S. Doss, R. Anubhai, S. Mallya, Y. Al-Onaizan, and D. Roth, "Label semantics for few shot named entity recognition," in *Findings of the association for computational linguistics: ACL 2022*, 2022, pp. 1956–1971. [Online]. Available: <https://aclanthology.org/2022.findings-acl.155/>
- [23] V. Moscato, M. Postiglione, and G. Sperli, "Few-shot Named Entity Recognition: Definition, Taxonomy and Research Directions," *ACM Transactions on Intelligent Systems and Technology*, vol. 14, no. 5, pp. 1–46, Oct. 2023. [Online]. Available: <https://dl.acm.org/doi/10.1145/3609483>
- [24] S. Srivastava, D. Gupta, B. Paul, and S. Sahoo, "A reinforced active learning sampling for cybersecurity NER data annotation," in *2022 OITS International Conference on Information Technology (OCIT)*. IEEE, 2022, pp. 312–317. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/10053727/>
- [25] A. Brilingaitė, L. Bukauskas, A. Juozapavičius, and E. Kutka, "Overcoming information-sharing challenges in cyber defence exercises," *Journal of Cybersecurity*, vol. 8, no. 1, p. tyac001, Jan. 2022. [Online]. Available: <https://academic.oup.com/cybersecurity/article/doi/10.1093/cybersec/tyac001/6516499>
- [26] L. Nitz, M. Akbari Gurabi, M. Cermak, M. Zadnik, D. Karpuk, A. Drichel, S. Schäfer, B. Holmes, and A. Mandal, "On Collaboration and Automation in the Context of Threat Detection and Response with Privacy-Preserving Features," *Digital Threats*, vol. 6, no. 1, pp. 5:1–5:36, Feb. 2025. [Online]. Available: <https://dl.acm.org/doi/10.1145/3707651>
- [27] M. A. Gurabi, O. Sen, N. Rahimidanesh, A. Ulbig, and S. Decker, "Enhancing Cyber Threat Intelligence Sharing through Data Spaces in Critical Infrastructures," in *2025 IEEE International Conference on Cyber Security and Resilience (CSR)*, Aug. 2025, pp. 83–90. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/11130001>
- [28] A. Albakri, E. Boiten, and R. De Lemos, "Sharing Cyber Threat Intelligence Under the General Data Protection Regulation," in *Privacy Technologies and Policy*, M. Naldi, G. F. Italiano, K. Rannenberg, M. Medina, and A. Bourka, Eds. Cham: Springer International Publishing, 2019, pp. 28–41.
- [29] Ministerio de Tecnologías de la Información y Comunicación (MITIC), "Boletines de Alertas de Ciberseguridad," May 2024. [Online]. Available: <https://www.datos.gov.py/dataset/boletines-de-alertas-de-ciberseguridad>
- [30] I. N. de Ciberseguridad (INCIBE), "Bitácora de ciberseguridad." [Online]. Available: <https://www.incibe.es/incibe-cert/publicaciones/bitacora-ciberseguridad>
- [31] L. Ratnov and D. Roth, "Design Challenges and Misconceptions in Named Entity Recognition," in *Proceedings of the Thirteenth Conference on Computational Natural Language Learning (CoNLL-2009)*, S. Stevenson and X. Carreras, Eds. Boulder, Colorado: Association for Computational Linguistics, Jun. 2009, pp. 147–155.
- [32] E. Zhu and J. Li, "Boundary Smoothing for Named Entity Recognition," in *Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, S. Muresan, P. Nakov, and A. Villavicencio, Eds. Dublin, Ireland: Association for Computational Linguistics, May 2022, pp. 7096–7108.
- [33] S. Silvestri, G. F. Russo, G. Tricomi, and M. Ciampi, "A Dataset for the Fine-tuning of LLM for the NER Task in the Cyber Security Domain," in *DS (LB) DS Late Breaking Contributions 2024*, vol. 3928, Pisa, Italy, 2024. [Online]. Available: https://iris.cnr.it/retrieve/71dc0d67-d484-452d-a4c2-d3df65691820/paper_170.pdf
- [34] M. Tkachenko, M. Malyuk, A. Holmanyuk, and N. Liubimov, "Label Studio: Data labeling software," 2020–2025, open source software available from <https://github.com/HumanSignal/label-studio>. [Online]. Available: <https://github.com/HumanSignal/label-studio>
- [35] U. Zaratianna, N. Tomeh, P. Holat, and T. Charnois, "GLiNER: Generalist Model for Named Entity Recognition using Bidirectional Transformer," in *Proceedings of the 2024 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies (Volume 1: Long Papers)*, K. Duh, H. Gomez, and S. Bethard, Eds. Mexico City, Mexico: Association for Computational Linguistics, Jun. 2024, pp. 5364–5376.

Un Marco Unificado de Aprendizaje Profundo Multicabeza para la Detección del Ciberacoso

Enrique García-Arias*, Antonio Robles-Gómez*, Rafael Pastor-Vargas*, Llanos Tobarra*,
Pedro Vidal-Balboa†

*Departamento de Sistemas de Comunicación y Control, ETSI Informática
Universidad Nacional de Educación a Distancia (UNED)
Madrid, España

Email: {e.garcia,arobles,rpastor,llanos}@scc.uned.es

†Consorcio CA UNED en Ponferrada / INTECCA
León, España
Email: pvidal@intecca.uned.es

Resumen—Los sistemas de detección del ciberacoso se basan en gran medida en procesos de clasificación binaria que no contemplan la naturaleza multidimensional de estas interacciones dañinas. Nuestra investigación introduce modelos expertos que identifican indicadores de riesgo como la amenaza o el odio, entre otros, para estructurarlos como dimensiones semánticas en el texto base e integrar el diagnóstico del ciberacoso en el marco de las estrategias de prevención de amenazas en ciberseguridad.

Nuestro diseño modular asocia a cada indicador de riesgo mecanismos de autoatención multicabeza (*multi-head self-attention*, MHSA) preservando su autonomía con una aproximación novedosa y eficiente en el ámbito de la detección del ciberacoso.

Nuestros resultados superan varios escenarios sobre corpus heterogéneos en español, donde se evidencia una reducida disponibilidad de referencias en comparación con la lengua inglesa, lo que exige una mayor robustez y eficacia, especialmente en escenarios de bajos recursos lingüísticos.

Index Terms—Ciberacoso, Procesamiento de Lenguaje Natural (PLN), Metadatos lingüísticos, Ciberseguridad

I. INTRODUCCIÓN

El ciberacoso es una amenaza digital donde las señales lingüísticas deben considerarse indicadores de riesgo. Sin embargo, actualmente la mayoría de los métodos de detección se limitan a una clasificación binaria, una simplificación que ignora la interacción de factores como la amenaza, el odio o el sexismo. Omitir esta complejidad limita la generalización y la interpretabilidad.

En nuestro trabajo, abordamos este proceso como un flujo de factores de riesgo → dimensiones semánticas → *Smart Tokens* (en adelante, Smart Tokens), donde modelamos el ciberacoso como un fenómeno complejo que surge de la interacción de factores de riesgo que configuran cómo se expresa y se percibe la intención dañina. Se trata de un tratamiento especializado para extraer e integrar estos indicadores de contenido semántico en el proceso de decisión final. Es crucial que estos indicadores no permanezcan implícitos como representaciones latentes, sino que sean accesibles al modelo de forma estructurada, transparente, activable e interpretable.

El entrenamiento de modelos especializados con corpus anotados de alta calidad permite inferir los factores de riesgo relevantes y en lugar de añadir estos indicadores únicamente como características adicionales, los representamos como

Smart Tokens, desvinculados del contenido léxico puro. A continuación, el mecanismo MHSA pondera y combina dinámicamente las representaciones textuales con estos indicadores semánticos, facilitando un enfoque selectivo en las señales más relevantes para cada predicción. **Cabe destacar que, aunque la autoatención es un concepto general, en este trabajo nos referimos específicamente a su implementación multicabeza (MHSA) propia de las arquitecturas *transformer*. Los Smart Tokens no solo mejoran la detección, sino que proporcionan indicadores adecuados para la evaluación de riesgos que pueden integrarse en procesos de monitorización y respuesta propios de la ciberseguridad.**

Nuestro modelo aborda las limitaciones de los enfoques unitarios, que no ofrecen claridad sobre la contribución de los factores de riesgo individuales, reduciendo la interpretabilidad y complicando los procesos de implementación. Al disociar la extracción de estos indicadores de la inferencia final sobre ciberacoso, nuestro marco mejora el control, facilita la reutilización entre conjuntos de datos y aumenta la robustez ante cambios distributivos.

A continuación resumimos las principales contribuciones:

- Superando el enfoque binario, el modelo de Smart Tokens es una representación estructurada de factores de riesgo, que vincula la detección de ciberacoso con las estrategias de evaluación de riesgos en ciberseguridad.
- Los indicadores de riesgo extraídos con modelos expertos se integran como dimensiones semánticas al texto analizado mediante el mecanismo MHSA.
- **El diseño modular de los procesos favorece la interpretabilidad (mediante la asociación de factores de riesgo con Smart Tokens) y la escalabilidad (al permitir añadir o eliminar módulos expertos de modo flexible).**
- Proporcionamos una evaluación experimental que destaca la eficacia del enfoque propuesto en varios escenarios de detección del ciberacoso.

En el ámbito de la investigación en español y a pesar de la relevancia del problema, encontramos una carencia estructural de conjuntos de datos anotados específicamente para ciberacoso y, como consecuencia natural, la dificultad de

contrastar nuestros resultados con estudios relevantes. Esta carencia hace más necesario profundizar en arquitecturas eficientes, flexibles, con amplias facilidades de parametrización, soporte de arquitecturas y gestión de resultados que permitan superar estas limitaciones de disponibilidad de datos.

II. TRABAJOS PREVIOS

De la revisión de los trabajos analizados concluimos que el ciberacoso amplifica su impacto más allá de la víctima individual para erigirse en una amenaza de seguridad digital, debido a su capacidad de escalar ataques vinculados con delitos de odio y otras ciberamenazas **islam_review_2023**. Desde esta óptica, estos contenidos constituyen un indicio temprano de riesgo, de forma similar a otras alertas utilizadas en sistemas de detección de incidentes en ciberseguridad.

Para avanzar en su prevención, es preciso implementar sistemas automáticos que mediante mecanismos de atención ante los indicadores de riesgo, ofrezcan recursos eficaces para la detección temprana, la priorización de alertas y el apoyo a la intervención humana **heinz_how_2025**. Las propuestas actuales de detección del ciberacoso están evolucionando hacia un análisis contextual que, integrado en los flujos de ciberseguridad, aporte explicabilidad y contexto semántico a la toma de decisiones, superando la simple clasificación binaria.

La evolución tecnológica de estos sistemas de detección automatizada del ciberacoso parte del uso de algoritmos clásicos de aprendizaje (SVM, Naive Bayes, Random Forest), apoyados en características léxicas superficiales como n-gramas o TF-IDF **mahmud2023cyberbullying, van_hee_automatic_2018**. Estas estrategias son eficaces en condiciones de lenguaje explícitamente ofensivo, pero ofrecen una capacidad muy limitada para capturar agresiones implícitas como el sarcasmo, la ironía y agresiones verbales que requieren conocimiento del contexto sociocultural **teng2023cyberbullying**.

Las limitaciones del enfoque de clasificación binaria se han intentado superar con el desarrollo de trabajos que incorporan dimensiones semánticas adicionales, entre las que destacamos: emociones y afectividad **chiril_emotionally_2022**, polaridad de sentimiento **Fortuna**, tipos de abuso (odio, amenaza, sexismo) **poletto_resources_2021**, direccionalidad del ataque y objetivo **basile2019hateval**, intensidad o severidad del daño **ABARNA2022105283**.

Estos enfoques constatan que el daño no depende solo de la presencia de lenguaje ofensivo, sino de una combinación de factores de riesgo presentes en el mensaje. Este requerimiento exige estrategias que incorporen estos factores de forma eficiente en los procesos de detección, aportando dimensiones semánticas asociadas al texto base. Algunos estudios han propuesto enfoques de aprendizaje multitarea (*multi-task learning*) con el objetivo de modelar conjuntamente estos fenómenos, sin embargo, en la práctica, las representaciones totalmente compartidas a menudo conducen a un entrelazamiento de tareas (*task entanglement*), donde las tareas dominantes eclipsan a las más débiles o menos frecuentes, particularmente en conjuntos de datos muy desequilibrados **rottger2022multilingual**. Además, el ajuste fino (fine-tuning) multitarea de extremo a extremo (end-to-end) suele producir representaciones latentes densas con mecanismos internos de decisión difíciles de interpretar y controlar **mozafari2019bert**.

En contraste, el uso de modelos de lenguaje de gran tamaño (Large Language Models, LLMs), como GPT-4 y Llama-2, ofrece un rendimiento competitivo incluso en escenarios *zero-shot*, pero como contrapartida a los resultados positivos, sus mecanismos de decisión son opacos, lo que dificulta aislar o controlar la influencia de factores de riesgo específicos. Además, su despliegue en entornos de producción plantea retos con respecto al coste computacional, la privacidad de los datos y la reproducibilidad. Todo ello dificulta la integración en sistemas de seguridad reales, donde es necesario comprender qué señales activan una alerta y con qué grado de certeza.

La Tabla I resume los principales enfoques en la detección de ciberacoso identificados en la literatura, sus limitaciones y la contribución de nuestra propuesta en una de ellas.

Tabla I. Comparativa de enfoques.

Técnica	Limitaciones	Contribución
SVM, NB, RF con n-gramas, TF-IDF mahmud2023cyberbullying, van_hee_automatic_2018	No capturan sarcasmo, ironía van_hee_automatic_2018	Uso de <i>transformers</i> multilingües (DeBERTa) que capturan contexto semántico
Análisis de emociones chiril_emotionally_2022 , sentimiento Fortuna , tipos de abuso poletto_resources_2021	Dimensiones tratadas de forma aislada chiril_emotionally_2022	Integración simultánea de múltiples factores de riesgo como Smart Tokens.
Aprendizaje multitarea con <i>hard parameter sharing</i> rottger2022multilingual, mozafari2019bert	<i>Task entanglement</i> : tareas dominantes eclipsan a las minoritarias	Arquitectura modular que preserva autonomía de cada indicador mediante atención dedicada.
GPT-4, Llama-2 en escenarios <i>zero-shot</i>	Opacidad, alto coste computacional, falta de trazabilidad	Explicabilidad inherente mediante Smart Tokens que participan en la atención.
Recursos en español limitados y con anotaciones simplificadas Ranasinghe	Escasez de datasets ricos en español; falta de taxonomía compartida	Arquitectura optimizada (Smart Tokens, MHSA) que, con recursos limitados, supera a modelos especializados.

Entre los conjuntos de datos en español que hemos utilizado, **TASS villena2013tass** proporciona anotaciones de sentimiento (positivo/negativo/neutro) en tuits en español, **EXISTS plaza2024exist** se centra en la detección de sexismo con anotaciones binarias y multiclase, **Hateval basile2019hateval** incorpora etiquetas de odio, agresividad y tipo de objetivo (individual vs. grupo) en inglés y español, constituyendo un banco de pruebas de referencia y el **Spanish Hate Speech Superset toneau2023spanish** aporta anotaciones binarias de odio complementadas con metadatos geográficos.

Para la validación en escenarios heterogéneos, se emplean corpus con variantes nacionales y temáticas: **Peruvian Twitter Cuzcano2020ACO** anota cuatro tipos de ciberacoso en tuits peruanos y latinoamericanos; **Offendes plaza2021offendes** reúne más de 47.000 comentarios en español de Twitter, Instagram y YouTube con cinco categorías de ofensividad; el corpus **Multilingual roy2023multilingual** proporciona anotaciones en 15 idiomas; y el corpus **Chileno arango-monnar-et-al-2022-resources** permite la valida-

ción en español de Chile.

Nuestro análisis afronta explícitamente el reto que representa la limitación de estos enfoques desde una perspectiva de ciberseguridad, conscientes de que, aunque hay recursos valiosos en castellano para odio, ofensividad, sentimiento y sexismo, es preciso desarrollar un enfoque que integre de forma eficiente estos factores de riesgo como dimensiones semánticas en un modelo de ciberacoso de modo que pueda demostrar su eficacia de forma homogénea en distintos conjuntos de datos.

Los resultados muestran cómo el tratamiento del ciberacoso puede integrarse en un ciclo de gestión de incidentes que incorpora la detección, el análisis, la respuesta y la prevención. Los factores de riesgo juegan un papel fundamental en esta ecuación por lo que dejan de ser representaciones latentes implícitas o objetos de un análisis post-hoc, para configurar dimensiones semánticas Smart Tokens que interactúan con las representaciones textuales mediante mecanismos MHSA.

III. METODOLOGÍA DE INVESTIGACIÓN




Figura 1: Arquitectura del sistema.

La Figura 1 ilustra el flujo de entrenamiento (arriba) y de producción (abajo) donde los modelos C y D operan en inferencia encadenada sobre el texto de entrada.

Fase I: Extracción segmentada de factores de riesgo

El flujo de trabajo de la Figura 2 se basa en modelos expertos independientes que modelan las dimensiones semánticas auxiliares correspondientes a los factores de riesgo que enriquecen el corpus principal.

Modelos expertos auxiliares: Entrenamos N modelos especializados, para cada dimensión semántica específica (por ejemplo, sentimiento, sexismo, odio, amenaza, objetivo).

Generación de corpus enriquecido: Las predicciones de los modelos expertos se transforman en etiquetas categóricas discretas incorporadas al corpus principal. El resultado es un corpus enriquecido con indicadores de factores de riesgo validados, que alimentan la siguiente fase del proceso.

Control de calidad con umbral de confianza: Para mitigar el ruido en las predicciones categóricas, aplicamos un filtro de confianza con umbral δ . Las predicciones con confianza inferior a δ se asignan a tokens <UNKNOWN>, permitiendo al modelo *downstream* aprender a interpretar la ausencia de señal fiable y evitando el problema de “falsa certeza”.

Fase II: Aprendizaje multitarea unificado con compartición rígida de parámetros

El objetivo de esta fase es entrenar una representación conjunta e interpretable de los factores de riesgo, generadas como salidas optimizadas de un codificador compartido. En la Figura 2 se muestran los tres componentes jerárquicos:




Figura 2: Aprendizaje multitarea unificado.

Codificador compartido (Shared Encoder): El codificador basado en *transformers* genera representaciones de tokens contextualizadas que se comparten entre todas las tareas.

Núcleo compartido (Shared Trunk): Las representaciones agrupadas (pooled) son transformadas mediante capas densas con activación no lineal y regularización *dropout*. Este núcleo (*hard parameter sharing*), asegura que los gradientes de todas las tareas dan forma conjunta a la representación latente.

Cabezas específicas de tarea (Task-Specific Heads): Cada factor de riesgo se asocia a un cabezal de salida optimizado con una función de pérdida dedicada (*binary cross-entropy*, *focal-loss*, o *regression loss*), estas tareas se entrenan simultáneamente en un único (*forward pass*).

Cada dimensión semántica se predice explícitamente mediante su propio cabezal de salida, lo que favorece la interpretabilidad, al tiempo que elimina la latencia y los costos de mantenimiento que se producen con los modelos externos.

Fase III: Inferencia unificada para la detección del ciberacoso

En la etapa final, el modelo de detección de ciberacoso opera sobre el corpus enriquecido que integra los factores de riesgo provenientes de las fases anteriores como se muestra en la Figura 3.

Preprocesamiento de inyección: Antes de la tokenización, se generan los Smart Tokens en base a los factores de riesgo. De forma parametrizable, pueden priorizarse qué factores de riesgo inyectar, utilizar el *umbral de confianza* δ para filtrar predicciones de baja certeza y determinar si se codifican todas las categorías o solo se refuerzan las señales positivas.

Arquitectura dual: Smart Tokens vs. Extra Features: El mecanismo de fusión flexible opera en dos modos: (a) Smart Tokens, donde los factores residen en el espacio de embeddings del *transformer* y participan en el mecanismo MHSA, permitiendo que el modelo aprenda asociaciones contextuales dinámicas; (b) *Extra Features*, donde los valores se concatenan

post-pooling como vectores numéricos independientes. Esta dualidad arquitectónica permite comparar de forma directa varias estrategias bajo condiciones idénticas de entrenamiento.

Aprendizaje y representación conjunta: En modo Smart Tokens, la representación del texto y los factores de riesgo se computan conjuntamente mediante MHSA. Al compartir la misma representación latente que el texto, el modelo aprende ponderaciones adaptativas entre contenido léxico y señales semánticas estructuradas. El cabezal de clasificación final proyecta esta representación enriquecida hacia la predicción de ciberacoso.

Análisis dinámico de importancia de factores: Durante el entrenamiento, el sistema extrae métricas de atención y gradientes para cuantificar la contribución de cada factor de riesgo a la predicción final. Estos valores se acumulan epoch a epoch, generando un histórico que permite: (i) identificar qué dimensiones son discriminatorias para el corpus específico; (ii) ajustar en caliente la selección de factores (p. ej., eliminar dimensiones que introducen ruido); y (iii) comparar el impacto relativo de Smart Tokens frente a *Extra Features*. Este proceso configura el ciclo de optimización, que permite iterar sobre la configuración óptima sin modificar la arquitectura base.




Figura 3: Flujo Late Fusion.

Integramos los factores de riesgo como Smart Tokens (p. ej., <HATE_YES>) en lugar de características *Extra Features* por dos razones. En primer lugar, los tokens residen en el espacio de *embeddings* del *transformer*, y el mecanismo MHSA aprende las asociaciones contextuales entre los tokens y el texto (p. ej., que <THREAT_YES> preste atención a verbos agresivos). Sin embargo, las *Extra Features*, concatenadas tras el agrupamiento *post-pooling*, carecen de esta interacción dinámica. En segundo lugar, los tokens proporcionan una auditabilidad explícita, ya que la predicción activada por <TARGET_IND><THREAT_YES> revela claramente el flujo del razonamiento, mientras que las categorías adicionales requieren un análisis post-hoc.

La codificación de los factores de riesgo en dimensiones semánticas Smart Tokens permite que el *transformer* los integre directamente en el mecanismo MHSA, lo que, en comparación con la fusión tardía de características externas (véase Tabla IV), se traduce en una mejora de 2,1 puntos en F_1 (86,0 % frente a 83,9 %).

IV. EXPERIMENTOS Y EVALUACIÓN

Configuración experimental

Los experimentos se ejecutan en una estación de trabajo equipada con una GPU NVIDIA RTX 4700 utilizando un

desarrollo propio basado en una arquitectura modular de aprendizaje profundo diseñada para la investigación sistemática en la detección automática de contenidos de riesgo. Su modelo desacoplado permite alternar entre codificadores *transformer* (DeBERTa, RoBERTa, XLM-R) y arquitecturas LSTM bidireccionales, bajo idénticas condiciones de entrenamiento.

Esta flexibilidad de diseño soporta tanto características externas *Extra Features* como Smart Tokens con MHSA. El módulo de entrenamiento implementa *early stopping* configurable sobre múltiples métricas (F_1 -macro, balanced accuracy, MCC), monitorización de métricas por clase, y extracción de representaciones intermedias para análisis de importancia de los factores de riesgo, con soporte para precisión mixta (AMP) y entrenamiento multi-GPU.

Esta versatilidad permite realizar múltiples configuraciones experimentales parametrizadas via JSON variando *embeddings* base, capas congeladas, *dropout* (0,3–0,5), estrategias de *pooling* (*mean*, *max*, *attention-based*), esquemas de pérdida (*cross-entropy*, *focal loss* con α y γ configurables) con ponderación dinámica de clases y esquemas de optimización adaptativos (AdamW con *schedulers cosine*, *plateau* o cíclicos), incluyendo *gradient clipping* y acumulación de gradientes simulando lotes de ejecución grandes en hardware limitado.

Estrategia de aumento de características

Este proceso se realiza en dos fases:

Generación de etiquetas externas: Entrenamos los modelos expertos especializados: Modelo A para sentimiento y Modelo B para misoginia.

Enriquecimiento del corpus principal: Utilizamos el conjunto de datos HatEval como base por sus anotaciones de odio, agresividad y objetivo. Los modelos A y B se aplican incorporando las dimensiones semánticas de sentimiento y sexismo.

A continuación, se describe el entrenamiento utilizado en cada proceso. En las tablas resumen, con **negrita** se indica mejor resultado propio, el fondo gris refleja los resultados de referencia externa.

Modelo A Sentimiento: Se parte del conjunto de datos TASS2019 **sepln2023tass**, **perez2023pysentimiento** un conjunto de datos organizado por la SEPLN. La Tabla II refleja los resultados de la tarea de clasificación de sentimiento con el modelo BERT en español dccuchile/bert-base-spanish-wwm-cased preentrenado con datos de dominio general.

Tabla II. Rendimiento base clasificación sentimiento.

Modelo	Aug.	Acc.	$F_{1,macro}$	$F_{1,NEG}$	MCC
BERTweet	No	0.897	0.899	0.810	0.742
BERTweet	Yes	0.854	0.816	0.732	0.634
BERT villena2013tass	Yes	–	0.671	–	–

La última fila indica los resultados reportados por los equipos participantes en SEPLN (*TASS task within IberLEF 2020 workshop*) **villena2013tass** concretamente el equipo ELiRF-UPV utilizando la variante monolingüe en Español (F_1 : 0,671, Precisión: 0.673, Recall: 0.670), superado por nuestro modelo.

El aumento de datos, realizado con sustitución de sinónimos y traducción inversa, no solo no mejora el rendimiento, sino que puede resultar contraproducente al introducir ruido semántico en un dominio que exige una comprensión contextual. Estos resultados nos confirman la necesidad de desplazar el foco desde tácticas genéricas de aprendizaje profundo hacia enfoques centrados en la semántica, el contenido y la naturaleza específica del ciberacoso, incorporando las dimensiones semánticas de los indicadores de riesgo.

Modelo B Sexismo: Utilizamos el conjunto de datos *EXISTS plaza2024exist* presentado en CLEF 2024, compuesto por textos con lenguaje sexista, frecuentemente implícito e irónico. Seleccionamos dos arquitecturas ampliamente utilizadas en tareas de clasificación multilingüe: el modelo monolingüe RoBERTaP (PlanTL-GOB-ES-roberta-base-bne), preentrenado en grandes corpus de español peninsular, y el modelo multilingüe XLM-RoBERTa, que permite evaluar la transferencia de conocimiento entre idiomas. Esta selección permite comparar dos enfoques complementarios: la especialización lingüística frente a la generalización multilingüe. El modelo multilingüe obtiene el peor rendimiento (80.1 %), confirmando la ventaja del preentrenamiento específico en español.

Nuestra estrategia técnica combina: (i) congelamiento de 9 capas *transformer* para preservar representaciones lingüísticas, (ii) *class weights* direccionales (1.2×YES) para compensar la ligera desproporción, y (iii) *early stopping* monitoreando F_1 de la clase minoritaria (YES).

Nuestra configuración, alcanza 81.9 % de F_1 , superando en +2.5 puntos porcentuales al mejor sistema NYCU-NLP EXIST 2024 *plaza2024exist* (79.4 %). Estos resultados indican que nuestro modelo logra mejor equilibrio entre precisión y *recall* en la detección de sexismo.

Tabla III. Resultados en detección de sexismo (EXISTS).

Modelo	Loss	Acc.	F_1	MCC
RoBERTaP-es	Cross-Entropy	0.819	0.819	0.639
XLM-RoBERTa	Cross-Entropy	0.801	0.801	0.605
EXIST 2024 <i>plaza2024exist</i>	–	0.840	0.794	–

Modelo C (MultiHead): El modelo C es una arquitectura diseñada para el aprendizaje multitarea. En esta etapa, se utiliza el conjunto de datos SemEval HatEval *manolescu2019tueval*, *basile2019hateval* organizado por la ACL, que aporta anotaciones nativas de odio, amenaza y objetivo (target). Los modelos A y B se aplican al conjunto de datos incorporando las etiquetas de sentimiento y sexismo, estos datos enriquecidos permiten entrenar el Modelo C, diseñado para el aprendizaje multitarea. A diferencia de los flujos de trabajo en cascada, este modelo impone una representación latente compartida entre las tareas, permitiendo capturar las interdependencias entre las dimensiones semánticas.

Para garantizar la calidad del entrenamiento y mitigar el ruido en las dimensiones semánticas, aplicamos un filtro de confianza con umbral $\delta = 0.85$ según los principios del *Confident Learning northcutt2021confident*. Las predicciones con confianza inferior a δ se asignan al token <UNKNOWN>, excluyéndose del cálculo de la pérdida (loss function) en el entrenamiento. Este mecanismo implementa efectivamente una atención rígida sobre señales fiables, evitando que las prediccio-

nes de baja confianza degraden la capa de *embeddings* común, como resultado, se genera un corpus enriquecido donde cada instancia dispone de cinco indicadores de factores de riesgo validados: odio, amenaza, objetivo, sentimiento y sexismo. Con esta combinación, la red aprende a identificar correlaciones en la detección del discurso de odio, como la fuerte asociación entre los ataques individuales (<THREAT_YES>) y el contenido sexista (<SEXISM_YES>).

En la evaluación de resultados se probaron varios enfoques representativos del estado del arte en la tarea de detección de odio en el corpus HatEval. Como referencia inicial, incluimos los resultados del workshop SemEval 2019 utilizando LSTM *manolescu2019tueval*, que establecen un baseline con arquitecturas recurrentes. Analizando arquitecturas más avanzadas, evaluamos configuraciones basadas en XLNet (autoregresiva) y BERT con focal loss, esta última diseñada específicamente para mitigar el desbalanceo de clases en el corpus. Además, incorporamos dos trabajos posteriores que reportan resultados en el mismo corpus: RoBERTa-BNE *Marquez2025CrossDomainCD*, un modelo monolingüe español, y la arquitectura LSTM de CEATIC *Plaza2020Detecting*. Esta selección cubre un espectro amplio de enfoques, desde arquitecturas recurrentes (LSTM) hasta *transformers* (XLNet, BERT, RoBERTa), permitiendo una evaluación exhaustiva de nuestra propuesta.

Tabla IV. Tabla de rendimiento con HatEval

Backbone	F_1	Precisión	Recall	
XLNet	0.780	0.786	0.785	0
XLNet (refined)	0.789	0.795	0.787	0
BERT + Focal	0.824	0.825	0.825	0
LSTM Base <i>manolescu2019tueval</i>	0.612	0.629	0.608	
roBERTa-BNE <i>Marquez2025CrossDomainCD</i>	0.791	0.795	0.787	
LSTM (CEATIC) <i>Plaza2020Detecting</i>	0.704	0.707	0.713	0

Nuestros resultados reflejados en la Tabla IV superan los trabajos del *workshop* SemEval utilizando LSTM y también superan los reportados por *Marquez2025CrossDomainCD* con RoBERTa-BNE demostrando consistencia en todas nuestras métricas: F_1 superior (+0,002), recall significativamente mayor (+1,6 puntos) para capturar casos positivos, y MCC que valida la calidad de las predicciones independientemente del desbalanceo del corpus.

Modelo D, detección de ciberacoso

El Modelo C entrenado en el paso anterior es el utilizado en producción cuando empezamos a clasificar un nuevo texto según indicado en la Figura 1 en el paso de producción. A continuación, comparamos nuestra arquitectura utilizando un modelo generalista de referencia PlanTL-GOB-ES-roberta-base-bne con un modelo especializado *delarosajav95/HateSpeech-BETO-cased-v2* que ha sido entrenado específicamente en el mismo corpus utilizado en nuestros experimentos *toneau2023spanish*.

Nuestra propuesta, utilizando un modelo generalista, supera al modelo especializado entrenado específicamente en el mismo corpus de evaluación, lo que teóricamente debería conferirle una significativa ventaja pues el modelo ya “conoce” el dominio y las características lingüísticas del corpus. Las mejoras son:

Tabla V. Comparativa de rendimiento

Métrica	Especializado	Propio	Mejora
Accuracy (%)	84.66	86.09	+1.43
Precisión SI (%)	73.26	72.22	-1.04
Recall SI (%)	64.15	69.63	+5.48
$F_{1,SI}$ (%)	68.40	70.90	+2.50
$F_{1,NO}$ (%)	89.87	90.86	+0.99
$F1_{\omega}$ (%)	84.31	86.00	+1.69
Precisin $_{\omega}$ (%)	84.18	85.93	+1.75
Recall $_{\omega}$ (%)	84.66	86.09	+1.43
MCC	0.580	0.618	+0.038

- $F_{1,SI}$ (+2.50 puntos): La métrica más importante para tareas desbalanceadas.
- Recall SI (+5.48 puntos): Lo que representa un aumento relativo del 8.5 % en la detección de casos reales.
- MCC (+6.6 % relativo): Mejor correlación matricial, indicando un modelo más robusto y equilibrado.

El modelo especializado obtiene una precisión SI (+1.04 puntos), ampliamente compensada con nuestra mejora en recall; en la detección del ciberacoso, es preferible revisar algunos falsos positivos que perder casos reales de acoso.

Comparativa sobre otros conjuntos de datos

En la Tabla VI mostramos la capacidad de generalización del modelo aplicado a cinco corpus heterogéneos, con $F_{1,\omega} > 0,82$ en todos los casos, destacando OffendES (0.917) y el corpus peruano (0.865).

Tabla VI. Resultados comparativa

Corpus	$F1_{\omega}$	$F1_{SI}$	Prec. $_{SI}$
OffendES plaza2021offendes	0.917	0.731	0.724
Hate Speech toneau2023spanish	0.860	0.709	0.722
Multilingual srivastava_hindi_2024	0.827	0.624	0.678
Peruvian Cuzcano2020ACO	0.865	0.739	0.754
Chileno arango-monnar-et al-2022-resources	0.825	0.855	0.816

Destacamos la estabilidad del valor de $F_{1,SI}$ la precisión y el recall de la clase que señala el ciberacoso, se mantienen en rangos muy competitivos incluso en los casos más exigentes como son el conjunto de datos multilingüe ($F_{1,SI} = 0,624$, $MCC = 0,634$) o chileno, donde alcanzamos el mejor equilibrio entre exhaustividad y precisión en la clase positiva ($F_{1,SI} = 0,855$, $Rec_{SI} = 0,898$). Además, los valores de MCC, todos en torno a 0,62–0,68, refuerzan la capacidad discriminativa del modelo aplicado a distribuciones de datos y esquemas de anotación muy distintos, lo que valida su generalización más allá de un único dataset.

Ablación

El estudio de ablación presentado en la Tabla VII evalúa el impacto de diferentes estrategias manteniendo invariantes el corpus, la arquitectura base y el modelo.

Nuestra estrategia de inyección de conocimiento lingüístico mediante Smart Tokens supera consistentemente tanto el

Tabla VII. Comparativa de arquitecturas

Escenario	$F1_{\omega}$	$F1_{SI}$	MCC	Acc $_{\omega}$
1. Baseline (sin features)	0.8385	0.6856	0.5772	0.8031
2. + Features	0.8393	0.6836	0.5755	0.7995
3. + Tokens (5)	0.8485	0.6839	0.5857	0.7881
4. + Tokens (2)	0.8600	0.7090	0.6178	0.8051

baseline como las *Extra Features*. La configuración óptima con 2 tokens ([hate], [threat]) alcanza mejoras sustanciales en todas las métricas clave: $F_{1,\omega} = 0,8600$ (+2.15pp), $F_{1,SI} = 0,7090$ (+2.34 pp) y $MCC = 0,6178$ (+4.06 pp). La expansión del vocabulario a 5 tokens con la inclusión de señales potencialmente irrelevantes produce una mejora marginal en métricas globales pero estanca el rendimiento en la clase minoritaria ($F_{1,SI} = 0,6839$), evidenciando que es precisa la correcta priorización de las dimensiones lingüísticas.

Detalles de Configuración para Reproducibilidad

Para facilitar la reproducibilidad de los experimentos, la Tabla VIII resume los principales hiperparámetros utilizados.

Tabla VIII. Hiperparámetros principales por modelo.

Parámetro	Modelo B	Modelo C	Ciberacoso
Learning rate (η)	$1,8 \times 10^{-5}$	$2,0 \times 10^{-5}$	$8,0 \times 10^{-6}$
Warmup steps	800	200	400
Weight decay	0.018	0.03	0.01
Dropout	0.37	0.6	0.3
Capas congeladas	9	4	3
Batch size	16	16	32
Grad. accumulation	2	2	1
Loss	79 (p90)	95 (p90)	65 (p90)
optimizer	Cross-entropy	Focal loss	Focal loss
Pooling mode	meanmax	weightedmean	attention

La división de los datos se realizó de forma estratificada manteniendo la proporción de clases, con un 70 % para entrenamiento, 15 % para validación y 15 % para prueba. En todos los casos el scheduler usado es Cosine Decay y el optimizador AdamW. El preprocesado de los textos incluyó el tokenizador PlanTL-GOB-ES-roberta-base-bne para los Modelos B y Ciberacoso y microsoft/deberta-base para el modelo C (Consolidador). Los experimentos se ejecutaron en una estación de trabajo con GPU NVIDIA RTX 4700, utilizando PyTorch 2.3 y la librería transformers de Hugging Face.

Para mitigar el desequilibrio de clases, se aplicaron técnicas de *class weighting* en los modelos B y D, y *focal loss* en el modelo C. El criterio de parada temprana (*early stopping*) se configuró para monitorizar el F1 de la clase minoritaria, asegurando la mejor capacidad de detección de casos positivos. Como resultado, el entrenamiento se detuvo en la época 9 para el Modelo B, época 14 para el Modelo C y época 10 para el Modelo D.

Los factores de riesgo seleccionados como Smart Tokens (odio, amenaza, sexismo, objetivo) se fundamentan en la literatura previa [poletto_resources_2021](#),

chiril_emotionally_2022. Su contribución relativa se validó mediante el análisis de importancia de características (ver Figura 4), que permitió priorizar aquellos con mayor impacto en la predicción final.




Figura 4: Importancia relativa de los factores de riesgo

V. DISCUSIÓN

Nuestros resultados experimentales demuestran la eficiencia de nuestro modelo, una mejora de rendimiento que se debe a tres decisiones de diseño:

1. *Especialización de codificadores*: Los modelos expertos (A, B, C) emplean codificadores independientes seleccionados empíricamente para cada corpus y tarea de identificación del factor de riesgo. Optimizar el modelo o sustituir un factor de riesgo por otro requiere reentrenar solo el cabezal y no todo el flujo de trabajo.
2. *Compartición en inferencia unificada*: El modelo final (D) emplea un único codificador compartido entre todos los indicadores de riesgo, evitando la acumulación de parámetros de arquitecturas separadas, el codificador compartido reduce la latencia y exigencia de memoria.
3. *Explicabilidad*: A diferencia de los enfoques basados en LLM, donde las contribuciones semánticas permanecen latentes, nuestro diseño de Smart Tokens permite generar explicaciones estructuradas sin depender de técnicas post-hoc como LIME o SHAP. Cada indicador de riesgo asociado al texto incluye el grado de certeza asignado y su importancia respecto de los tokens de contenido.

Desde la perspectiva de las implicaciones en la ciberseguridad, el análisis semántico multidimensional propuesto proporciona un mecanismo estructurado para identificar, caracterizar y priorizar interacciones potencialmente dañinas que pueden escalar hacia amenazas más graves. Los factores de riesgo analizados como dimensiones semánticas pueden actuar como indicadores complementarios dentro de marcos de seguridad más amplios, apoyando procesos de priorización de alertas, paneles de evaluación de riesgo o mecanismos de toma de decisiones.

VI. LIMITACIONES Y AMENAZAS A LA VALIDEZ

Una amenaza a la validez está relacionada con la elección de los factores de riesgo a identificar (odio, amenaza, objetivo, sentimiento y sexismo), y aunque se fundamenta en la literatura previa y está respaldada por evidencia empírica, deriva de una conceptualización concreta del fenómeno del ciberacoso y otras dimensiones potencialmente relevantes como el desequilibrio de poder, la repetición en el tiempo, el sarcasmo o el historial contextual entre usuarios, no han sido incluidas, por lo que sería preciso una evaluación más amplia y contrastada de estas posibles manifestaciones adicionales del ciberacoso.

Una limitación estructural que afecta a toda la investigación en español es la escasez de conjuntos de datos anotados para ciberacoso. Esta situación se agrava con el fuerte desequilibrio de clases, con una tasa de ejemplos positivos que oscila entre el 5 % y el 28 % según el corpus. Para abordar este problema, hemos empleado *class weighting* y *focal loss*, estrategias que mejoran el recall de la clase minoritaria (Tabla VII) pero no eliminan por completo la mayor sensibilidad del modelo hacia la clase mayoritaria.

En segundo lugar, la escasez de datos introduce sesgos geográficos y culturales. Los corpus disponibles en español provienen predominantemente de España, Perú, Chile y México, lo que limita la generalización a otras variantes dialectales. Además, las anotaciones de odio y sexismo pueden reflejar sesgos propios de los anotadores, un problema reconocido en la literatura, aunque difícil de cuantificar sin estudios específicos de concordancia. Estos sesgos no han sido evaluados explícitamente en este trabajo, por lo que constituyen una amenaza a la validez externa de nuestros resultados. No obstante, nuestra metodología está diseñada para ser transferible a otros contextos lingüísticos y geográficos, siempre que se disponga de los corpus adecuados.

VII. CONCLUSIONES Y FUTUROS TRABAJOS

La arquitectura que hemos descrito demuestra que el modelado de los factores de riesgo mediante Smart Tokens logra un rendimiento sólido ($F_1 = 0,860$, $MCC = 0,618$) a la vez que mantiene la interpretabilidad y la eficiencia de implementación. Adicionalmente, al reducir la carga computacional, nuestro sistema podría integrarse en dispositivos con recursos limitados o en plataformas de monitorización en tiempo real que requieran baja latencia.

Además de la eficiencia, la capacidad semántica del modelo aborda una de las mayores críticas a los modelos de lenguaje actuales: la opacidad. Mientras que los modelos monolíticos actúan como “cajas negras”, nuestro modelo ofrece una trazabilidad que permite a los moderadores/SOC entender qué factores de riesgo (odio, sexismo, amenaza, objetivo o sentimiento) y con qué peso y certidumbre han activado la alerta de ciberacoso. Este equilibrio entre el alto rendimiento de los modelos y la interpretabilidad de los metadatos lingüísticos sugiere que nuestra propuesta se orienta como una solución robusta y ética para la protección en entornos digitales.

Nuestro trabajo aporta una metodología replicable para contextos de escasez de recursos lingüísticos. Ante la inexistencia de datasets consolidados en español para ciberacoso, la exploración sistemática del conjunto de hiperparámetros, facilitada por nuestro framework modular, presenta rendimientos competitivos en reducidos volúmenes de datos anotados. Esta aproximación es transferible a otras lenguas con similar limitación de recursos.

Como trabajos futuros que puedan extender las capacidades desarrolladas por nuestro modelo mencionamos incorporar nuevos factores de riesgo mediante modelos expertos adicionales y el desarrollo de interfaces de auditoría que implementen herramientas de visualización interactiva que permitan a moderadores/SOC activar factores de riesgo, ajustar umbrales de confianza δ en tiempo real y generar reportes con trazabilidad orientada al cumplimiento normativo.

AGRADECIMIENTOS

Los autores desean agradecer el apoyo del Gobierno de España (a través del Instituto Nacional de Ciberseguridad de España, INCIBE), con el Proyecto de Investigación Estratégico “Análisis de aplicaciones móviles desde la perspectiva de la protección de datos: Ciberprotección y Ciberriesgos de la información ciudadana”, así como la Cátedra Internacional “Smart Rural IoT y Entornos Seguros”, en el contexto del Plan de Recuperación, Transformación y Resiliencia financiado por la Unión Europea (NextGenerationEU/PRTR). Los autores también agradecen el soporte del Consorcio del Centro Asociado UNED Ponferrada. INTECCA, así como el grupo de investigación UNED CiberCSI y el grupo de innovación docente UNED CiberGID.

DECLARACIÓN SOBRE EL USO DE IA GENERATIVA Y TECNOLOGÍAS ASISTIDAS POR IA EN EL PROCESO DE ESCRITURA

Durante la preparación de este trabajo, los autores han utilizado herramientas de IA generativa con el fin de encontrar sinónimos para palabras que se usan con frecuencia en el texto, para evitar repeticiones y hacer que el manuscrito sea más fácil de leer y más variado en cuanto a léxico. Después de utilizar esta herramienta, los autores revisaron y editaron el contenido según fuera necesario y asumieron la responsabilidad total por el contenido de la publicación.

¿Son capaces los Grandes Modelos de Lenguaje de comprender eventos de seguridad?

Fernando Jesús García-Molina, Roberto Magán-Carrión y Antonio Ropa Muñoz

Network Engineering & Security Group (NESG)

Research Centre for Information and Communication Technologies (CITIC-UGR)

University of Granada, Granada, Spain.

fergarcia@correo.ugr.es, rmagan, aropa@ugr.es

Abstract—En el ecosistema digital actual, caracterizado por infraestructuras altamente interconectadas y una dependencia creciente de los sistemas tecnológicos, la ciberseguridad se ha convertido en un desafío operativo central para las organizaciones. Los Centros de Operaciones de Seguridad (SOC) deben analizar diariamente grandes volúmenes de logs y alertas procedentes de múltiples fuentes heterogéneas, en un contexto en el que las amenazas son cada vez más sofisticadas y automatizadas.

En los últimos años, la Inteligencia Artificial ha emergido como una herramienta clave para apoyar estas tareas, y en particular, los Grandes Modelos de Lenguaje (LLM) han demostrado capacidades prometedoras para procesar y razonar sobre información textual compleja. Estudios recientes señalan su potencial para analizar datos de logs, reducir falsos positivos, proporcionar explicaciones contextuales y asistir en la respuesta a incidentes de seguridad.

Sin embargo, a pesar del creciente interés en su aplicación, sigue siendo necesario evaluar de forma sistemática la capacidad de estos modelos para comprender e interpretar correctamente eventos de seguridad, lo que representa el objetivo principal de este trabajo.

Index Terms—Cybersecurity, Large Language Models (LLMs), Security Alerts, Prompt Engineering, Wazuh, SIEM, Artificial Intelligence for Cybersecurity.

Contribution type: *Ongoing investigation*

I. INTRODUCCIÓN

Hoy en día vivimos en un mundo interconectado, donde personas y dispositivos están en continua comunicación. Este escenario, que aporta múltiples servicios útiles para la sociedad, se antoja peligroso desde el punto de vista de la ciberseguridad, ya que, entre otros aspectos, aumenta la superficie de exposición y ataque frente a actores maliciosos. Informes recientes, como el *ENISA Threat Landscape 2024* [1], describen un entorno cada vez más sofisticado y automatizado, en el que los ataques no solo aumentan en número, sino también en coordinación y capacidad de evasión. De cara al futuro, el *ENISA 2030 Threat Outlook* [2] advierte que esta tendencia se verá reforzada por la adopción de técnicas basadas en inteligencia artificial por parte de los atacantes. Al mismo tiempo, la escasez persistente de profesionales cualificados en ciberseguridad agrava la carga de trabajo de los equipos

defensivos, limitando su capacidad de respuesta y aumentando los tiempos de detección y contención de incidentes, tal y como señalan informes del sector como el *Global Security Operations Center Study Results IBM* [3].

Este escenario es especialmente relevante en los Centros de Operaciones de Seguridad (SOC), donde la adopción de herramientas como los sistemas de Gestión de Información y Eventos de Seguridad (SIEM), los Sistemas de Detección de Intrusiones (IDS), los Sistemas de Prevención de Intrusiones (IPS) y las soluciones de Detección y Respuesta en el *End-point* (EDR) ha incrementado de forma significativa la capacidad de detección, pero también el número de alertas generadas. Diversos estudios industriales destacan que este crecimiento en el volumen de alertas no siempre se traduce en una mejora proporcional de la seguridad, sino que puede provocar una sobrecarga operativa que dificulta la identificación temprana de incidentes reales [3]. Como consecuencia, los equipos SOC se enfrentan a problemas bien conocidos, como la fatiga por alertas, la dificultad para mantener reglas de detección actualizadas y una fuerte dependencia del conocimiento experto para interpretar correctamente los eventos de seguridad.

La actividad diaria en un entorno de ciberseguridad moderno está dominada por el análisis continuo de alertas generadas por múltiples sistemas de monitorización. Cada una de estas alertas puede indicar desde un comportamiento benigno hasta el inicio de un incidente grave, lo que obliga a los analistas a realizar tareas de triaje constantes, altamente repetitivas y dependientes del contexto. En la práctica, este proceso se ve condicionado por la presión temporal, la falta de información completa y la necesidad de priorizar rápidamente entre grandes volúmenes de eventos concurrentes, factores que incrementan el riesgo de errores humanos y retrasos en la respuesta ante incidentes [3].

En este contexto, la inteligencia artificial ha emergido como un elemento clave para apoyar las operaciones de seguridad. En particular, las técnicas de automatización y aprendizaje automático han demostrado su utilidad para acelerar la detección de

anomalías y reducir los tiempos de respuesta ante incidentes [4]. No obstante, como señalan diversos estudios [4], la supervisión humana sigue siendo imprescindible: aunque los algoritmos son eficaces en la identificación de patrones, la interpretación contextual y la toma de decisiones críticas continúan requiriendo juicio experto.

En los últimos años, los Grandes Modelos de Lenguaje (o LLMs (Large Language Models) de sus siglas en inglés) han adquirido un papel destacado dentro de este ecosistema [4]. A diferencia de enfoques tradicionales, los LLM destacan por su capacidad para procesar información textual compleja y heterogénea, lo que los convierte en candidatos idóneos para el análisis de alertas de seguridad, la detección de anomalías y el apoyo a la respuesta a incidentes. Los estudios recientes proponen múltiples aproximaciones en esta línea, desde la extracción automática de patrones y plantillas en grandes volúmenes de alertas, hasta la asistencia en tareas de triaje, contextualización y explicación de eventos de seguridad [4].

Asimismo, se han explorado enfoques que combinan LLM con fuentes externas de inteligencia de amenazas, arquitecturas de Generación Aumentada por Recuperación (o RAG (Retrieval Augmented Generation) de sus siglas en inglés) y agentes autónomos capaces de ejecutar flujos de respuesta parcialmente automatizados [4]. Estos avances sugieren que los LLM no solo pueden mejorar la eficiencia del análisis, sino también integrarse de manera realista en los flujos de trabajo de los SOC. Sin embargo, su adopción plantea desafíos relevantes relacionados con la fiabilidad de las respuestas, la explicabilidad de las decisiones, la privacidad de los datos y el riesgo de uso malicioso de la propia tecnología [4].

En este escenario, resulta necesario evaluar de forma sistemática la capacidad de los LLM para comprender e interpretar correctamente alertas de seguridad. Por ello, este trabajo se centra en analizar la capacidad de los LLM para razonar sobre alertas, sintéticas y reales, derivadas de datos de logs de sistemas finales y responder a preguntas relevantes para la resolución de incidentes en entornos SOC. Así, a lo largo del presente trabajo, se intentará dar respuesta a la pregunta: *¿son los Grandes Modelos de Lenguaje capaces de comprender e interpretar alertas de seguridad de forma precisa y útil para apoyar la resolución de incidentes?*

Los resultados obtenidos muestran que los LLM son capaces de identificar eventos básicos, resumir alertas y responder con precisión razonable a preguntas estructuradas, con mejor rendimiento en escenarios sintéticos que en entornos reales. Se observa que los modelos comerciales ofrecen mayor robustez frente a datos ruidosos, mientras que todos los modelos evaluados presentan limitaciones ante alertas reales caracterizadas por heterogeneidad y falta de contexto explícito, lo que refuerza su papel como herramientas

de apoyo al analista más que como sustitutos del mismo.

II. FUNDAMENTOS

Esta sección presenta los conceptos, tecnologías y el contexto de investigación necesarios para comprender el resto de este trabajo, así como el estado actual de la investigación en relación al análisis de alertas y eventos de seguridad con LLM.

A. Gestión de logs y alertas de seguridad

La gestión de logs ha evolucionado desde una actividad puramente operativa hasta convertirse en un pilar central de la ciberseguridad. En sus inicios, los logs de sistema se utilizaban principalmente para la resolución de fallos técnicos o la auditoría de cambios de configuración. Sin embargo, a medida que las infraestructuras han aumentado en escala y complejidad y las amenazas se han vuelto más sofisticadas, los logs han pasado a ser una fuente primaria de evidencia para la detección de amenazas, la respuesta a incidentes y el análisis forense [4].

Los entornos Tecnología de la información (TI) modernos generan grandes volúmenes de logs procedentes de fuentes diferentes, como sistemas operativos, aplicaciones, dispositivos de red, servicios en la nube y herramientas de seguridad. Estos registros incluyen eventos del sistema, acciones de usuario, intentos de autenticación, cambios de configuración y anomalías detectadas. Su naturaleza temporal permite a los analistas reconstruir el comportamiento de los sistemas y analizar incidentes una vez ocurridos.

Dado el volumen y la heterogeneidad de esta información, el análisis manual resulta inviable en la práctica. Como consecuencia, la monitorización de seguridad ha evolucionado hacia el uso de **alertas**, que representan abstracciones procesadas, correlacionadas y priorizadas de los eventos originales. Las alertas están diseñadas para resaltar comportamientos anómalos o potencialmente maliciosos que requieren la atención del analista.

Plataformas centralizadas como los SIEM recopilan y normalizan logs de múltiples fuentes, generando alertas mediante reglas de correlación, firmas o técnicas de detección de anomalías. Herramientas como Wazuh o Splunk son ampliamente utilizadas en los SOC para apoyar la monitorización en tiempo real y la respuesta a incidentes.

B. Grandes Modelos de Lenguaje

Los Grandes Modelos de Lenguaje son modelos de inteligencia artificial entrenados sobre grandes volúmenes de texto con el objetivo de comprender y generar lenguaje natural. La mayoría de los LLM actuales se basan en la arquitectura Transformer [5], que emplea mecanismos de atención para capturar dependencias de largo alcance dentro de secuencias textuales. Esta capacidad les permite razonar sobre información compleja y semiestructurada, lo que los

hace especialmente adecuados para tareas de ciberseguridad relacionadas con logs y alertas [4] para, potencialmente, mitigar los problemas actuales relacionados con la gestión de alertas por parte de equipos y personas que integran un SOC como son, entre otras, la cantidad y heterogeneidad de dichas alertas.

a) *Ingeniería de prompts*: Un aspecto clave en el uso de LLM es la **ingeniería de prompts**, que consiste en el diseño de instrucciones en lenguaje natural para guiar el comportamiento del modelo. Son muchas las técnicas existentes hoy en día para realizar la ingeniería de *prompts* aunque las más relevantes son¹: *zero-shot*, *few-shot* y *chain-of-thought*. Con **zero-shot prompting**, el modelo recibe instrucciones directas sin ejemplos previos. Este enfoque permite una rápida adaptación a distintas tareas de análisis de alertas sin necesidad de reentrenamiento, aunque puede presentar limitaciones en escenarios altamente especializados o críticos.

De forma complementaria, la técnica **few-shot prompting**, en la que se proporcionan al modelo uno o varios ejemplos representativos de entrada y salida antes de plantear la tarea objetivo. Estos ejemplos actúan como guía implícita, permitiendo al modelo inferir el formato esperado de la respuesta y el tipo de razonamiento que debe aplicar. Según investigaciones previas [6], el uso de ejemplos explícitos permite al modelo captar mejor el objetivo de la tarea en situaciones donde una instrucción directa resulta insuficiente, favoreciendo respuestas más consistentes y alineadas con el propósito definido. No obstante, el uso de *few-shot prompting* presenta ciertas limitaciones prácticas. En primer lugar, el número y la calidad de los ejemplos influyen directamente en el rendimiento del modelo, lo que introduce un componente adicional de diseño y experimentación. Además, al incluir ejemplos explícitos en el prompt, se incrementa el consumo de *tokens*, reduciendo el espacio disponible en la ventana de contexto para los propios datos de entrada.

En su lugar, la técnica conocida como **chain-of-thought prompting** se basa en inducir al modelo a razonar paso a paso antes de generar una respuesta final, haciendo explícito el proceso lógico que sigue para llegar a una conclusión. Este enfoque ha demostrado mejorar el rendimiento de los LLM en tareas que requieren razonamiento más complejo y multietapa, como la identificación de patrones o la correlación de eventos. [7]. En el contexto del análisis de alertas y logs de seguridad, este tipo de prompting permite que el modelo interprete la información de forma más estructurada, relacione distintos eventos entre sí y ofrezca conclusiones más justificadas y comprensibles para un analista. No obstante, el uso de *chain-of-thought* también implica un mayor consumo de *tokens* y puede generar razonamientos intermedios innecesarios, lo que supone una limitación en escenarios con

restricciones de ventana de contexto o en entornos operativos donde se priorizan respuestas más directas y concisas.

b) *tokens y ventana de contexto*.: Los LLM procesan el texto convirtiéndolo en unidades más pequeñas denominadas **tokens**, que pueden corresponder a palabras, subpalabras o símbolos. La **ventana de contexto** define el número máximo de *tokens* que el modelo puede procesar simultáneamente, incluyendo tanto la entrada como la salida.

Esta restricción resulta especialmente relevante en el análisis de logs y alertas, ya que los conjuntos de datos pueden contener miles de líneas. Dado que no es viable proporcionar archivos completos a un LLM, es necesario aplicar técnicas de preprocesado como filtrado, agregación o segmentación para seleccionar subconjuntos representativos y relevantes de la información.

C. Análisis de logs y alertas basado en IA

El crecimiento en volumen y complejidad de las alertas de seguridad ha motivado una intensa investigación sobre la aplicación de técnicas de inteligencia artificial, y más recientemente de Grandes Modelos de Lenguaje, en las operaciones de los SOC. A diferencia de los enfoques tradicionales basados exclusivamente en reglas, las soluciones basadas en LLM buscan aportar comprensión contextual, adaptabilidad y una mejor colaboración humano-máquina.

III. ESTADO DEL ARTE

Diversos trabajos han abordado este problema desde perspectivas complementarias. Estos son:

- **RuleGenie** [8]: Este trabajo se centra en la gestión de reglas de detección en plataformas SIEM como Splunk. Mediante el uso de LLM, RuleGenie identifica reglas redundantes o solapadas y propone optimizaciones que mejoran la cobertura de amenazas y reducen los falsos positivos, disminuyendo la carga de trabajo de los analistas.
- **Rule-ATT&CK Mapper (RAM)** [9]: RAM aborda la desconexión entre reglas de detección de bajo nivel y la inteligencia de amenazas de alto nivel. Utilizando inferencia basada en *prompts* con modelos como GPT-4, permite mapear automáticamente reglas SIEM a tácticas y técnicas del marco MITRE ATT&CK, mejorando la comprensión contextual de las alertas.
- **LogGPT** [10]: LogGPT propone un modelo inspirado en GPT entrenado para predecir entradas posteriores en secuencias de logs. Las desviaciones entre los eventos esperados y los observados se utilizan para detectar comportamientos anómalos, lo que resulta especialmente útil para identificar ataques.
- **LogPrécis** [11]: Este trabajo aplica LLM al análisis de trazas de comandos en sistemas Unix,

¹<https://www.promptingguide.ai/>

extrayendo significado semántico de las secuencias. Permite identificar tácticas sospechosas, generar huellas de sesión y agrupar comportamientos similares, siendo especialmente relevante para análisis forense.

- **ChatIDS** [12]: ChatIDS explora el uso de LLM para traducir alertas de IDS a explicaciones comprensibles en lenguaje natural. Además, sugiere acciones de mitigación, facilitando la comunicación entre perfiles técnicos y no técnicos, aunque plantea retos en términos de confianza y privacidad.
- **Evaluating Three Large Language Models for Security Incident Detection and Analysis** [13]: Este trabajo propone un enfoque basado en LLM integrados en flujos de trabajo del SOC, donde procesan alertas estructuradas procedentes del SIEM, realizan correlación semántica de eventos mediante razonamiento en lenguaje natural y apoyan la priorización de incidentes a través de reglas y prompts predefinidos.
- **LLM Agents for SOC Triage** [14]: Este estudio analiza cómo LLM como GPT-4, Claude o LLaMA2 pueden asistir a analistas de primer nivel en tareas de triaje de alertas, integrándose con SIEMs de código abierto como Wazuh y mostrando mejoras en eficiencia, aunque con desafíos en consistencia.
- **Automated Threat Response with LLM Agents** [15]: Este trabajo propone agentes autónomos basados en LLM capaces de analizar alertas, correlacionar eventos y ejecutar playbooks de respuesta, avanzando hacia SOC's más automatizados y destacando la necesidad de supervisión humana.
- **CORTEX** [16]: CORTEX propone una arquitectura multi-agente basada en LLM para el triaje de alertas en SOC's, donde agentes especializados analizan comportamiento, recopilan evidencias y razonan de forma colaborativa. El enfoque reduce falsos positivos y mejora la calidad de las investigaciones frente a soluciones basadas en un único modelo.
- **CTIBench** [17]: CTIBench introduce un benchmark específico para evaluar el rendimiento de los LLM en tareas propias de un SOC, como la extracción de indicadores de compromiso, el análisis de inteligencia de amenazas y la generación de informes técnicos. El estudio permite comparar modelos en escenarios realistas de ciberseguridad, proporcionando métricas objetivas para su uso operativo.
- **Towards Effective Identification of Attack Techniques in CTI Reports** [18]: Este trabajo analiza el uso de LLM para identificar técnicas de ataque en informes de inteligencia de amenazas y mapearlas al marco MITRE ATT&CK. Es un enfoque bastante interesante porque demuestra

que estos modelos pueden extraer información relevante de textos complejos de ciberseguridad. Sin embargo, se centra en informes de inteligencia ya redactados, por lo que no queda claro si estas capacidades se mantendrían al trabajar directamente con las alertas que genera un SIEM en producción.


- **Using Large Language Models for Template Detection from Security Event Logs** [19]: Aquí los autores investigan si los LLM pueden detectar plantillas recurrentes en logs de seguridad, algo que en la práctica ayudaría mucho a reducir el ruido y a que los analistas no se pierdan entre miles de eventos repetidos. Los resultados son positivos, pero el trabajo se queda en la detección de patrones estructurales y no entra a valorar si el modelo realmente comprende qué está pasando en esos eventos ni si sería capaz de razonar sobre ellos como lo haría un analista.
- **LLMs in the SIEM Loop** [20]: Este trabajo propone meter los LLM directamente dentro del flujo de detección de un SIEM y evalúa cómo de bien mapean los eventos de telemetría de Windows al framework MITRE ATT&CK. La propuesta tiene mucho sentido desde el punto de vista práctico y los resultados son alentadores, aunque la evaluación se hace sobre un entorno bastante específico. Esto hace que sea difícil saber cómo se comportarían estos modelos en escenarios más heterogéneos o con alertas procedentes de infraestructuras distintas a las probadas.

En conjunto, los estudios existentes ponen de manifiesto el potencial de los LLM para mejorar el análisis de logs y alertas mediante una mayor contextualización, la reducción de falsos positivos y el apoyo a la toma de decisiones por parte de los analistas. No obstante, persisten retos abiertos relacionados con la fiabilidad, la explicabilidad, la privacidad y la integración en entornos de producción. Este trabajo se apoya en estas contribuciones para evaluar de forma específica la capacidad de los LLM para comprender y razonar sobre alertas de seguridad derivadas de datos de logs.

IV. METODOLOGÍA

Esta sección describe la metodología seguida para evaluar la capacidad de los Grandes Modelos de Lenguaje para comprender y razonar sobre alertas de seguridad derivadas de datos de logs. El enfoque propuesto busca reproducir un escenario operativo realista de un SOC, en el que un asistente basado en inteligencia artificial actúa como apoyo al analista humano durante el proceso de análisis e interpretación de alertas.

La Figura 1 presenta una visión general del flujo metodológico adoptado en este estudio, destacando las distintas etapas que abarcan desde la generación de datos hasta la evaluación de los resultados.



(a) Enfoque metodológico

Figure 1. Visión general del flujo metodológico adoptado en este estudio, desde la generación de logs y la extracción de alertas hasta el análisis y evaluación mediante LLM.

La metodología se estructura en tres fases principales: (i) generación/recopilación de datos y pre-procesado, (ii) generación de conjuntos de datos para la evaluación, y (iii) evaluación.

A. Generación/recopilación de datos y pre-procesado

Con el objetivo de garantizar tanto el realismo como la reproducibilidad del estudio, se adoptó una estrategia híbrida para la generación y recopilación de datos. Por un lado, se desplegó un entorno experimental controlado destinado a la generación de logs sintéticos relevantes desde el punto de vista de la seguridad. Por otro, se incorporaron datos reales procedentes de un entorno de monitorización en producción, cedidos por la Universidad de Granada.

El entorno experimental está compuesto por varias máquinas virtuales que simulan componentes habituales de una infraestructura empresarial, incluyendo sistemas monitorizados, nodos atacantes y servicios de gestión de seguridad. En este contexto se ejecutaron tanto actividades benignas como ataques simulados, tales como intentos de autenticación no autorizados, escaladas de privilegios y ejecución de *malware*. Estas acciones fueron monitorizadas mediante Wazuh², una plataforma de seguridad que integra capacidades de detección de intrusiones basadas en correlación de eventos tipo SIEM y funcionalidades próximas a EDR.

De forma complementaria, se incorporó un conjunto de alertas reales generadas en producción perteneciente a la Universidad de Granada. Estos datos reflejan eventos observados en un entorno operativo real, aportando una variabilidad y complejidad que resulta difícil

de reproducir en escenarios controlados. Su inclusión permite evaluar el comportamiento de los LLM no solo frente a escenarios simulados, sino también ante alertas auténticas propias de infraestructuras en uso.

De este modo, el conjunto de datos combina información sintética y real, lo que permite trabajar con escenarios más cercanos a los que se encuentran habitualmente en un SOC y aporta mayor solidez a los resultados obtenidos.

La Tabla I resume las principales características cuantitativas de ambos escenarios. En ella se distinguen: (i) el número total de alertas generadas inicialmente por el sistema de monitorización, (ii) el número de alertas preprocesadas y finalmente utilizadas en los experimentos tras aplicar los filtros y transformaciones descritos en la sección anterior, (iii) el número de agentes de monitorización desplegados y (iv) el número de máquinas efectivamente monitorizadas en cada caso.

Puede observarse que, aunque el escenario real presenta un volumen significativamente mayor de alertas generadas, el número de alertas finalmente seleccionadas para el análisis es reducido tras el proceso de filtrado, lo que pone de manifiesto la necesidad de técnicas de preprocesado para eliminar ruido y eventos redundantes.

El conjunto de alertas sintéticas generado durante el despliegue experimental se encuentra disponible públicamente en un repositorio GitHub, con el objetivo de facilitar la reproducibilidad de los experimentos y permitir su reutilización en trabajos futuros³.

²<https://wazuh.com/>

³<https://surl.li/hunfqa>

Table I
RESUMEN DE MONITORIZACIÓN POR ESCENARIO

Escenario	Alertas generadas	Alertas preprocesadas	Agentes desplegados	Máquinas monitorizadas
Escenario A: Sintético	731	126	1	1
Escenario B: Real	10000	44	4	4

a) *Preprocesado y extracción de alertas*: Las alertas de seguridad generadas por la plataforma estas constituyen el punto de partida del análisis. Estas alertas fueron sometidas a un proceso de preprocesado con el objetivo de mejorar su adecuación al análisis mediante diferentes LLM y optimizar su inclusión en los *prompts*.

El preprocesado se centró en la selección y estructuración de los campos más relevantes de cada alerta, tales como marcas temporales, identificadores de origen, descripciones del evento y niveles de severidad. Adicionalmente, se incorporó un contador que indica el número de veces que un mismo evento aparece en un intervalo determinado, permitiendo representar de forma compacta patrones repetitivos y reducir significativamente el número total de entradas proporcionadas al modelo.

Dadas las limitaciones asociadas a la ventana de contexto de los LLM, no resulta viable incluir grandes volúmenes de alertas individuales como entrada directa. Por este motivo, el proceso de agregación y reducción aplicado permite preservar la información contextual esencial necesaria para el razonamiento, al tiempo que se mantiene el tamaño de los *prompts* dentro de las restricciones de *tokens* del modelo.

B. Diseño de prompts e interacción con los LLM

La interacción con los LLM se llevó a cabo mediante el diseño de *prompts* cuidadosamente elaborados, orientados a evaluar sus capacidades de comprensión y razonamiento. Los *prompts* se formularon en lenguaje natural se incluyeron alertas de seguridad como entrada, seguidas de preguntas específicas relacionadas con su interpretación.

El estudio adopta principalmente una estrategia de **zero-shot prompting**⁴, en la que no se proporcionan ejemplos previos al modelo. En su lugar, se utilizan instrucciones directas con el fin de evaluar la capacidad del LLM para razonar a partir del conocimiento adquirido durante su entrenamiento. Las preguntas se agruparon en las siguientes categorías o tópicos:

- T1: Identificación de eventos básicos
- T2: Resumen del contenido de las alertas
- T3: Detección de patrones, anomalías o errores
- T4: Extracción de conclusiones
- T5: Preguntas de razonamiento con opciones múltiples

Este planteamiento permite una evaluación estructurada y repetible de diferentes habilidades de ra-

⁴Se puede ver un ejemplo de *prompt* utilizado en <https://surl.li/qrpmhd>

zonamiento relevantes para los flujos de trabajo de un SOC. Para aquellos lectores interesados, en la URL⁵ del repositorio de código asociado al trabajo se muestran todas y cada una de la preguntas evaluadas.

C. Generación de respuestas

Para cada *prompt*, el LLM genera una respuesta textual que refleja su interpretación de los datos de alerta proporcionados. Las respuestas se recopilaban sin aplicar ningún tipo de postprocesado, con el objetivo de evitar la introducción de sesgos externos. De este modo, la evaluación se centra en las capacidades intrínsecas de razonamiento de los modelos.

Se evaluaron múltiples modelos siguiendo exactamente el mismo procedimiento, lo que permite realizar comparaciones directas bajo condiciones idénticas.

D. Estrategia de evaluación

La fase de evaluación combina perspectivas cualitativas y cuantitativas. Para cada conjunto de alertas se definió una referencia verdadera (*ground truth*) basada en un análisis manual equivalente a la respuesta que daría un analista de seguridad con conocimiento experto.

Con el fin de reducir la variabilidad inherente a los modelos generativos, cada pregunta fue evaluada en cinco ejecuciones independientes por modelo. Las respuestas obtenidas se compararon manualmente con el *ground truth* y se clasificaron en una de las siguientes categorías: correcta, incorrecta, respuesta incompleta (faltan detalles) o no sabe/no contesta. Para cada pregunta se consideró como resultado final la categoría predominante entre las cinco ejecuciones, lo que permite mitigar efectos debidos a respuestas inconsistentes o aleatorias.

Se definió un sistema de puntuación discreto con el objetivo de diferenciar no solo entre aciertos y errores, sino también entre distintos grados de adecuación en las respuestas. Cada respuesta clasificada como correcta recibió una puntuación de 1 punto. Las respuestas consideradas incompletas (es decir, aquellas que identificaban parcialmente el fenómeno analizado pero omitían elementos relevantes) fueron puntuadas con 0,25 puntos, reflejando así un reconocimiento limitado de comprensión sin equipararlas a respuestas plenamente correctas. Las respuestas incorrectas y aquellas clasificadas como no sabe/no contesta recibieron una puntuación de 0 puntos. La puntuación total de un modelo se obtuvo como la suma de las puntuaciones individuales de todas las preguntas evaluadas.

⁵<https://github.com/Mush2h/LogIA>

El rendimiento global se calculó mediante la métrica de precisión, definida como la puntuación obtenida por el modelo normalizada por el número total de preguntas evaluadas:

$$\text{Precisión} = \frac{P_{\text{total}}}{N}$$

Donde P_{total} representa la suma de las puntuaciones asignadas a las respuestas del modelo y N el número total de preguntas evaluadas. Esta métrica se calculó tanto de forma global como desagregada por bloques temáticos, permitiendo analizar el comportamiento de los modelos en las diferentes tipos de tareas.

Dado que el problema evaluado no corresponde a una tarea de clasificación binaria tradicional, sino a la evaluación cualitativa de respuestas generativas abiertas, métricas clásicas como F1-score no resultan directamente aplicables sin redefinir el problema en términos de detección de elementos individuales. Por este motivo, se optó por un esquema de puntuación discreto adaptado al carácter interpretativo de la tarea.

V. EVALUACIÓN Y RESULTADOS

Esta sección presenta un análisis comparativo del rendimiento de los modelos en su capacidad para comprender e interpretar alertas de seguridad. La evaluación se realizó utilizando el mismo conjunto de alertas preprocesadas y los mismos *prompts* para todos los modelos, garantizando así condiciones homogéneas tanto en el escenario simulado como en el real.

Como se observa en la Figura 2, los modelos obtienen en general mejores resultados en el escenario simulado que en el real. En el entorno sintético el comportamiento es más homogéneo y consistente entre modelos, mientras que en el entorno real se aprecia mayor dispersión y un incremento de errores, probablemente debido al mayor ruido y complejidad de las alertas reales.

En cuanto a las temáticas, la Temática 1 (preguntas orientadas a la extracción de información básica de los eventos) es la que presenta peor rendimiento en el escenario simulado. Sin embargo, en el escenario real la que obtiene peores resultados es la Temática 5 (preguntas multirrespuesta inspiradas en CTIBench [17]). Esto sugiere que las tareas que requieren correlacionar varios elementos o razonar de forma estructurada se ven más afectadas cuando los datos provienen de un entorno real menos controlado.

Respecto a los modelos, DeepSeek muestra un rendimiento inferior al resto, especialmente en el escenario real. Además, aunque en el entorno simulado no se observan diferencias claras entre modelos de código abierto y modelos comerciales, en el escenario real los modelos de pago ofrecen resultados más sólidos y consistentes. Esto podría indicar que, en entornos de producción, los modelos comerciales presentan una mayor robustez frente a datos ruidosos o complejos.

VI. CONCLUSIONES

Los resultados obtenidos indican que los LLM son capaces de identificar correctamente eventos básicos, resumir información relevante y responder con un grado razonable de precisión a preguntas estructuradas, especialmente cuando el formato de la tarea guía explícitamente el razonamiento del modelo. En particular, las preguntas de opción múltiple han mostrado ser un mecanismo eficaz para reducir la ambigüedad en las respuestas y mejorar el rendimiento global, lo que sugiere que la forma en que se plantea la interacción con el modelo es un factor clave en su efectividad.

Sin embargo, el estudio también pone de manifiesto limitaciones importantes. El rendimiento de los modelos se degrada de forma notable cuando se enfrentan a alertas reales, caracterizadas por una mayor heterogeneidad, ruido y falta de contexto explícito. En estos escenarios, los LLM tienden a generar respuestas incompletas o excesivamente genéricas, lo que evidencia dificultades para captar matices operativos y relaciones implícitas entre eventos. Este comportamiento refuerza la idea de que, en su estado actual, los LLM no pueden sustituir al analista humano, sino que deben concebirse como herramientas de apoyo.

Asimismo, se ha observado que los modelos de mayor tamaño presentan una mejor capacidad para el razonamiento contextual y la extracción de conclusiones a partir de información parcial, mientras que los modelos más ligeros muestran mayores problemas de consistencia y profundidad analítica. Este aspecto introduce un compromiso práctico entre rendimiento, coste computacional y viabilidad de despliegue en entornos operativos reales.

En conjunto, los resultados permiten concluir que los Grandes Modelos de Lenguaje poseen un potencial significativo para asistir en tareas concretas del ciclo de gestión de alertas, como el triaje inicial, la contextualización de eventos y el apoyo a la toma de decisiones. Sin embargo, su utilización en entornos SOC debe realizarse de forma cautelosa, integrándolos dentro de flujos supervisados por expertos y complementándolos con técnicas adicionales de validación, enriquecimiento de contexto y control de calidad.

Como líneas de trabajo futuro, se plantea profundizar en el uso de técnicas de *prompting* más avanzadas, como enfoques híbridos que combinen técnicas *chain-of-thought* con formatos de respuesta estructurados, así como la integración de arquitecturas RAG para dotar a los modelos de conocimiento actualizado y específico del entorno monitorizado o el entrenamiento específico para este fin de modelos (*fine-tuning*). Del mismo modo, resulta de interés ampliar el conjunto de métricas de evaluación e incorporar estudios con analistas humanos en escenarios operativos reales, con el objetivo de evaluar el impacto práctico de estas herramientas en la eficiencia y calidad de las operaciones de seguridad.




Figure 2. Precisión por tema y modelo evaluado para (a) eventos simulados y (b) eventos reales.

AGRADECIMIENTOS

Esta publicación ha sido principalmente financiada por MICIN/AEI/10.13039/501100011033 bajo la ayuda PID2024-161902OB-I00 y por el proyecto NetSEA-GPT (C-ING-300-UGR23), apoyado por la Consejería de Universidad, Investigación e Innovación y la Unión Europea a través del Programa FEDER Andalucía 2021–2027.

REFERENCES

- [1] ENISA, “Enisa threat landscape 2024,” 2024, accessed: June 12, 2025. [Online]. Available: <https://www.enisa.europa.eu/publications/enisa-threat-landscape-2024>
- [2] —, “Foresight cybersecurity threats for 2030 - update 2024 (executive summary),” 2024, accessed: June 12, 2025. [Online]. Available: <https://www.enisa.europa.eu/publications/foresight-cybersecurity-threats-for-2030-update-2024-executive-summary>
- [3] IBM Security, “Cost of a data breach report 2024,” 2024, accessed: June 12, 2025. [Online]. Available: <https://www.ibm.com/reports/data-breach>
- [4] H. Xu *et al.*, “Large language models for cyber security: A systematic literature review,” *arXiv preprint arXiv:2405.04760*, Sep. 2025.
- [5] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, Kaiser, and I. Polosukhin, “Attention is all you need,” in *Advances in Neural Information Processing Systems*, vol. 30, 2017.
- [6] T. B. Brown, B. Mann, N. Ryder, and et al., “Language models are few-shot learners,” *Advances in Neural Information Processing Systems (NeurIPS)*, 2020.
- [7] J. Wei, X. Wang, D. Schuurmans, and et al., “Chain-of-thought prompting elicits reasoning in large language models,” *Advances in Neural Information Processing Systems (NeurIPS)*, 2022.
- [8] S. Shukla, R. Gandhi, Y. Elovici, and A. Shabtai, “Rulegenie: Siem detection rule set optimization using large language models,” *arXiv preprint arXiv:2505.06701*, 2025.
- [9] M. Wudali *et al.*, “Rule-att&ck mapper: Linking siem rules to mitre att&ck using llms,” *arXiv preprint arXiv:2504.12345*, 2025.
- [10] D. Han *et al.*, “Loggpt: Log anomaly detection with gpt-based models,” in *Proceedings of the ACM Conference on Computer and Communications Security (CCS)*, 2023.
- [11] F. Boffa *et al.*, “Logprécis: Large language models for unix command analysis,” in *Proceedings of the IEEE Symposium on Security and Privacy Workshops (SPW)*, 2023.
- [12] V. Jüttner, M. Grimmer, and E. Buchmann, “Chatids: Explainable cybersecurity using generative ai,” *arXiv preprint arXiv:2306.14504*, 2023. [Online]. Available: <https://arxiv.org/abs/2306.14504>
- [13] A. Mudzakir, J. T. A. Janaprasetya, E. Kayowuan, V. J. L. Engel, and B. Saputro, “Evaluating three large language models for security incident detection and analysis,” *Procedia Computer Science*, 2025. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1877050925026444>
- [14] V. Oniagbi, “Evaluation of llm agents for the soc tier 1 analyst triage process,” Master’s thesis, University College London, 2024.
- [15] P. Damola and A. Miracle, “Transforming security operations centers with llm agents for automated threat response and analysis,” *Cybersecurity and Law*, December 2024, accessed: August 2025. [Online]. Available: <https://www.researchgate.net/publication/387398201>
- [16] B. Wei, Y. S. Tay, H. Liu, J. Pan, K. Luo, Z. Zhu, and C. Jordan, “Cortex: Collaborative llm agents for high-stakes alert triage,” *arXiv preprint arXiv:2510.00311*, 2025. [Online]. Available: <https://arxiv.org/abs/2510.00311>
- [17] S. Alam *et al.*, “Ctbench: A benchmark for evaluating large language models in cyber threat intelligence,” *arXiv preprint arXiv:2401.05678*, 2024.
- [18] H. Cuong Nguyen, S. Tariq, M. Baruwat Chhetri, and B. Quoc Vo, “Towards effective identification of attack techniques in cyber threat intelligence reports using large language models,” in *Companion Proceedings of the ACM on Web Conference 2025*, 2025, pp. 942–946.
- [19] R. Vaarandi and H. Bahşi, “Using large language models for template detection from security event logs,” *International Journal of Information Security*, vol. 24, no. 3, p. 104, 2025.
- [20] G. Esposito, “LLMs in the SIEM loop: A contract-based framework for threat detection with an evaluation on Windows telemetry and MITRE ATT&CK mapping,” Doctoral dissertation, Politecnico di Torino, 2025.

Una revisión de “*The Machines are Watching: Exploring the Potential of Large Language Models for Detecting Algorithmically Generated Domains*”

Tomás Pelayo-Benedet
Universidad de Zaragoza
España
tpelayo@unizar.es

Ricardo J. Rodríguez
Universidad de Zaragoza
España
ricardo@unizar.es

Carlos H. Gañán
Delft University of Technology
Países Bajos
C.HernandezGanan@tudelft.nl

Resumen—Los Dominios Generados Algorítmicamente (AGDs) son parte de muchas campañas de malware modernas, permitiendo a los atacantes establecer canales de mando y control (C&C) resilientes. Si bien las técnicas de aprendizaje automático se emplean cada vez más para detectar AGDs, el potencial de los Modelos de Lenguaje Grandes (LLMs) en este ámbito sigue siendo escasamente explorado. En este trabajo evaluamos la capacidad de nueve LLMs comerciales para identificar AGDs maliciosos sin ajuste de parámetros ni entrenamiento específico, mediante enfoques zero-shot y few-shot con estrategias de prompting. Los resultados muestran que los LLMs alcanzan precisiones de detección entre el 77,3 % y el 89,3 %. Sin embargo, surgen limitaciones significativas frente al tráfico DNS real, donde la degradación del rendimiento ante dominios benignos que guardan similitudes estructurales con dominios maliciosos evidencia el riesgo de falsos positivos en entornos reales.

Index Terms—Modelos de Lenguaje Grandes, Dominios Generados Algorítmicamente, Análisis de Tráfico DNS, Detección de Malware

Tipo de contribución: Investigación ya publicada [6]

I. INTRODUCCIÓN

El cibercrimen se ha convertido en una industria altamente rentable que supera en ingresos al tráfico ilegal de drogas a nivel mundial [1]. Una técnica clave empleada por los atacantes son los Algoritmos de Generación de Dominios (DGA), que generan dinámicamente grandes cantidades de dominios posibilitando establecer conexión entre el malware y el centro de mando y control (C&C), dificultando que los defensores los bloqueen o rastreen [2]. Los DGA generan Dominios Generados Algorítmicamente (AGDs) mediante diversas técnicas pseudoaleatorias: métodos aritméticos, basados en hash, de diccionario y de permutación [3].

A pesar de más de 14 años de investigación en detección de AGDs ([4], [5]), no existen trabajos que utilicen directamente LLMs para esta tarea. Por ello, en nuestro trabajo evaluamos la capacidad de los LLMs para identificar AGDs sin ajuste de parámetros ni entrenamiento específico respondiendo a tres preguntas de investigación:

- **RQ1:** ¿Con qué eficacia detectan los LLMs AGDs maliciosos mediante análisis de cadenas de nombres de dominio? ¿Qué impacto tiene proporcionar características lingüísticas específicas de los DGAs?
- **RQ2:** ¿En qué medida pueden los LLMs distinguir entre diferentes familias de malware, para ello proveyendo a los modelos de ejemplos de AGDs de cada familia?

- **RQ3:** ¿Cómo se comportan los LLMs al evaluar dominios reales no maliciosos que comparten similitudes estructurales con AGDs maliciosos?

Este resumen extendido resume el trabajo publicado en [6].

II. CONFIGURACIÓN EXPERIMENTAL

Modelos evaluados. En nuestros experimentos hemos utilizado nueve LLMs de cuatro proveedores: GPT-4o y GPT-4o-mini (OpenAI), Claude Sonnet 3.5 y Haiku 3.5 (Anthropic), Gemini 1.5 Pro, Flash y Flash-8B (Google), y Mistral Large y Small (MistralAI).

Conjuntos de datos. Hemos construido tres *datasets*: D_1 con 50.000 dominios: 25.000 AGDs maliciosos de DGArchive [3] y 25.000 benignos de Tranco [7]; D_2 con 50.000 AGDs de 25 familias de malware representando esquemas aritmético, hash y diccionario; y D_3 con 50.000 dominios legítimos extraídos de los registros DNS de la Universidad de Zaragoza durante 347 días.

Estrategias de prompting. Para nuestros experimentos hemos diseñado cuatro prompts incrementales: P_1 , mínimo; P_2 , añade análisis de características léxicas de los dominios maliciosos; P_3 , añade ejemplos de 25 familias de malware; y P_4 añade contexto de dominios reales. Hemos utilizado un tamaño de lote de 125 dominios por llamada a la API.

III. DETECCIÓN DE AGDs (RQ1)

Sin ajuste específico, los LLMs alcanzan exactitudes entre 77,3 % y 89,4 %. Claude 3.5 Sonnet obtiene el mejor rendimiento general (Tabla I). Podemos observar una tendencia: los modelos más grandes obtienen mejores resultados.

Una limitación crítica es la elevada tasa de falsos positivos (FPR), entre 13,2 % y 31,9 %. En un entorno con un millón de consultas legítimas diarias, esto supondría bloquear erróneamente entre 132 000 y 319 000 dominios benignos cada día. Como muestra la Tabla I, las diferencias entre P_1 y P_2 son marginales en todos los modelos: las variaciones en exactitud no superan el punto porcentual. Los resultados nos muestran que para la tarea de la clasificación de binaria de AGDs el prompting avanzado no aporta mejoras significativas.

IV. CLASIFICACIÓN POR FAMILIA DE MALWARE (RQ2)

Para la clasificación multiclase, hemos seguido una estrategia en la que damos 10 ejemplos por familia (P_3), ya que en experimentos preliminares mostró el mejor equilibrio entre

Tabla I
RENDIMIENTO DE LOS LLMs EN DETECCIÓN BINARIA DE AGDs (D_1).

Modelo	P	Acc.	Prec.	Rec.	FPR
GPT-4o	P_1	86,8 %	83,6 %	91,4 %	17,9 %
	P_2	87,0 %	84,6 %	90,5 %	16,5 %
GPT-4o-mini	P_1	77,3 %	73,0 %	86,4 %	31,9 %
	P_2	78,5 %	74,6 %	86,5 %	29,4 %
Claude 3.5 Sonnet	P_1	89,3 %	83,8 %	97,4 %	18,8 %
	P_2	89,4 %	84,2 %	96,8 %	18,2 %
Claude 3.5 Haiku	P_1	85,6 %	84,0 %	87,9 %	16,8 %
	P_2	85,2 %	84,7 %	86,0 %	15,6 %
Gemini 1.5 Pro	P_1	87,7 %	83,8 %	93,5 %	18,1 %
	P_2	87,6 %	84,2 %	92,6 %	17,4 %
Gemini 1.5 Flash	P_1	84,8 %	83,5 %	86,9 %	17,2 %
	P_2	84,9 %	83,6 %	86,8 %	17,1 %
Gemini 1.5 Flash-8B	P_1	81,7 %	78,2 %	87,9 %	24,5 %
	P_2	82,7 %	79,8 %	87,6 %	22,1 %
Mistral Large	P_1	88,7 %	87,3 %	90,6 %	13,2 %
	P_2	88,5 %	87,1 %	90,5 %	13,4 %
Mistral Small	P_1	85,1 %	82,6 %	89,0 %	18,8 %
	P_2	85,5 %	83,7 %	88,1 %	17,1 %

exactitud y eficiencia. Los resultados varían significativamente según el esquema de generación (D_2).

Los DGAs basados en hash obtienen clasificación casi perfecta en todos los modelos: Claude 3.5 Sonnet alcanza precisión del 100 % en esta categoría. Los DGAs aritméticos presentan resultados mixtos: familias como *metastealer*, *rovnix* y *zloader* mantienen tasas de detección altas, pero *conficker* exhibe tasas más bajas a pesar de su mecanismo de generación más simple. Los DGAs de diccionario son los más difíciles de detectar, los modelos encuentran problemas a la hora de detectar dominios maliciosos compuestos por palabras naturales. Claude 3.5 Sonnet lidera con un F1-score global del 93,7 %, seguido de Gemini 1.5 Pro (79,6 %), Gemini 1.5 Flash-8B (56,8 %) y Mistral Large (41,4 %). El resto de modelos no son capaces de realizar esta tarea de clasificación multiclase ya que no superan el 40 % en F1-score.

V. RENDIMIENTO CON DOMINIOS REALES (RQ3)

Al evaluar sobre D_3 (tráfico DNS real) utilizando P_4 , todos los modelos muestran una degradación sustancial del rendimiento, tal y como se aprecia en la Figura 1. Los valores de exactitud con P_4 disminuyen entre un 11 % y un 24 % respecto a los dominios benignos de D_1 con P_1 y P_2 . En un despliegue con un millón de consultas diarias, esto equivaldría a entre 110 000 y 240 000 falsos positivos adicionales al día, sumados a los falsos positivos que ya se obtenían.

VI. CONCLUSIONES

Este trabajo presenta la primera evaluación sistemática del uso de LLMs para detectar AGDs maliciosos sin ajuste de parámetros. Los resultados muestran que los LLMs son capaces de distinguir dominios benignos y maliciosos con exactitudes de hasta el 89,4 %. Sin embargo, las altas tasas de falsos positivos, la degradación ante tráfico DNS real y las restricciones de latencia y coste representan obstáculos fundamentales para su despliegue en producción.

Los LLMs resultan más adecuados, en su estado actual, para un análisis posterior como la investigación forense que como componentes primarios de detección en sistemas de filtrado DNS en tiempo real. El trabajo futuro explorará




Figura 1. Exactitud de los LLMs sobre P_1 , P_2 usando D_1 y P_4 , D_3 .

arquitecturas en dos etapas, ajuste fino de modelos de código abierto sobre conjuntos de datos de DGA, y técnicas de compresión que permitan inferencia a velocidad de línea.

AGRADECIMIENTOS

Esta investigación ha sido financiada en parte por la ayuda PID2023-151467OA-I00 (CRAPER), financiada por MICIU/AEI/10.13039/501100011033 y por FEDER/UE; por la ayuda TED2021-131115A-I00 (MIMFA), financiada por MICIU/AEI/10.13039/501100011033 y por la Unión Europea NextGenerationEU/PRTR; por la ayuda *Proyecto Estratégico Ciberseguridad EINA UNIZAR*, financiada por el Instituto Nacional de Ciberseguridad (INCIBE) y la Unión Europea NextGenerationEU/PRTR; por la ayuda *Programa de Proyectos Estratégicos de Grupos de Investigación* (grupo de investigación DisCo, ref. T21-23R), financiada por el Dpto. de Universidad, Industria e Innovación del Gobierno de Aragón; y por el proyecto RAPID (Ayuda n.º CS.007) financiado por el Consejo de Investigación de los Países Bajos (NWO). Queremos expresar nuestro agradecimiento al equipo de DGArchive por habernos proporcionado el conjunto de datos actual por adelantado, lo que nos permitió comenzar la experimentación antes.

REFERENCIAS

- [1] Cybersecurity Ventures, “Cybercrime To Cost The World 10.5 Trillion Annually By 2025”, 2023. [En línea; <https://cybersecurityventures.com/cybercrime-damages-6-trillion-by-2021/>].
- [2] Porras, Phillip A., Hassen Saïdi, y Vinod Yegneswaran: “A Foray into Conficker’s Logic and Rendezvous Points.” En *LEET 9*: 7. 2009.
- [3] Plohmann, D., Yakdan, K., Klatt, M., Bader, J., y Gerhards-Padilla, E.: “A comprehensive measurement study of domain generating malware”. En *25th USENIX Security Symposium* (pp. 263-278). 2026.
- [4] Woodbridge, J., Anderson, H. S., Ahuja, A., y Grant, D. *et al.*: “Predicting Domain Generation Algorithms with Long Short-Term Memory Networks”. *arXiv preprint arXiv:1611.00791*. 2016.
- [5] Cebere, B. C., Flueren, J. L. B., Sebastián, S., Plohmann, D., y Rossow, C.: “Down to Earth! Guidelines for DGA-based Malware Detection”, en *Proc. 27th RAID*, pp. 147-165, 2024.
- [6] T. Pelayo-Benedet, R. J. Rodríguez, y C. H. Gañán: “The Machines are Watching: Exploring the Potential of Large Language Models for Detecting Algorithmically Generated Domains”, *Journal of Information Security and Applications*, 93, 104176. 2025.
- [7] Tranco List. [En línea; <https://tranco-list.eu/>]. Accedido en agosto de 2024.

A Review of ShaTS: A Shapley-based Explainability Method for Time Series Artificial Intelligence Models

Manuel Franco De La Peña, Ángel Luis Perales Gómez, Lorenzo Fernández Maimó

Departamento de Ingeniería y Tecnología de Computadores

Universidad de Murcia, Murcia, España

Email: {manuel.francop, angelluis.perales, lfmaimo}@um.es

Abstract—Explainability is a key requirement for the deployment of Artificial Intelligence models in industrial environments, where decisions must be transparent, actionable, and reliable. The reviewed work addresses fundamental limitations of post-hoc Shapley-based explainability methods when applied to anomaly detection over time series data. ShaTS introduces an a priori grouping strategy that embeds temporal and structural information directly into the Shapley computation, producing explanations that are both operationally meaningful and computationally viable. Experimental results on the SWaT dataset show that ShaTS substantially improves localization accuracy and explanation coherence compared to post-hoc SHAP approaches, while satisfying real-time constraints required in safety-critical industrial systems.

Index Terms—Anomaly Detection, Explainable Artificial Intelligence, Shapley Values, Industrial Internet of Things

Tipo de contribución: Trabajo científico publicado durante 2025 disponible en [1]

I. INTRODUCTION

Industrial Internet of Things (IIoT) environments increasingly depend on Machine Learning (ML) and Deep Learning (DL) models to detect cyberattacks and abnormal operating conditions. These models typically process multivariate time series generated by sensors and actuators deployed in critical infrastructures. Although detection accuracy has improved considerably, the opacity of these models remains a major obstacle for their adoption in operational environments, where human operators must understand alerts in order to act safely and effectively.

Explainable Artificial Intelligence (xAI) seeks to mitigate this issue by providing insight into model decisions. Among existing xAI approaches, Shapley value-based methods, such as SHAP [2], are particularly attractive due to their strong theoretical foundations in cooperative game theory. However, when applied to time-series data, conventional Shapley-based explainers exhibit structural limitations that significantly reduce their usefulness.

Most Shapley-based xAI methods process time-series data in a post-hoc manner, estimating the contribution of each feature at each time step independently and later aggregating these values to obtain higher-level explanations. This design ignores temporal and physical relationships inherent to the data and introduces several drawbacks. First, temporal de-

pendencies are not captured during attribution, leading to fragmented importance across adjacent instants. Second, aggregation across time or components is performed only after attribution, often producing noisy explanations that obscure the true source of anomalies. Finally, computational cost increases rapidly with window length, as Shapley values must be estimated for every time-step feature prior to aggregation, frequently exceeding real-time and memory constraints.

These limitations motivate the need for an xAI method that explicitly accounts for temporal structure and system semantics during the Shapley computation itself, rather than as a post-processing step.

II. SHATS: SHAPLEY VALUES FOR TIME SERIES MODELS

ShaTS is a model-agnostic xAI method designed specifically to overcome the shortcomings of post-hoc Shapley approaches in time series settings. The key design principle of ShaTS is the integration of domain-aware grouping into the Shapley game formulation before computing attributions.

Instead of treating each time-step independently, ShaTS defines groups that reflect meaningful temporal and structural relationships in the data. Shapley values are then computed directly over these groups, reducing the dimensionality of the attribution problem while preserving interpretability.

ShaTS supports three complementary grouping strategies:

- **Temporal Grouping**, which aggregates consecutive time instants within a window, enabling the identification of critical temporal segments influencing the model output.
- **Feature Grouping**, which groups variables associated with the same sensor, actuator, or physical component, producing explanations aligned with the system architecture.
- **Multi-Feature Grouping**, which combines temporal and feature-based groupings to provide higher-level explanations at the process level.

By embedding grouping into the Shapley computation, ShaTS avoids post-hoc aggregation artifacts and yields explanations that are temporally coherent, physically meaningful, and computationally efficient. The method is implemented as a plug-and-play, open-source xAI module¹, and can be

¹Available at <https://github.com/CyberDataLab/ShaTS>

integrated into existing ML/DL pipelines without modifying the underlying predictive models.

III. EXPERIMENTAL VALIDATION

The effectiveness of ShaTS is evaluated on an Anomaly Detection (AD) task using the Secure Water Treatment (SWaT) dataset [3], a widely adopted benchmark for industrial cybersecurity. SWaT comprises six processes (P1-P6) monitored through 51 sensors and actuators, and includes both normal operation and labeled cyberattacks with known injection points.

A bidirectional LSTM AD model is trained using 10-step windows, achieving an F1 score of 95.44% and detecting 21 out of 28 attacks in the test set. This model serves as the basis for xAI analysis.

Explanations are evaluated in terms of their ability to localize the attack source at two levels: affected process and specific sensor or actuator. ShaTS is compared against the KernelSHAP method of SHAP performing post-hoc aggregation, and computational viability and scalability are assessed by varying window length and background set size.

ShaTS consistently outperforms post-hoc SHAP in terms of actionability. Among the 21 detected attacks, ShaTS correctly identifies the affected sensor or actuator in 14 cases (versus 6 for KernelSHAP) and the affected process in 19 cases (versus 8). Post-hoc SHAP explanations frequently disperse importance across unrelated features, whereas ShaTS produces focused and interpretable attribution patterns. Figure 1 illustrates this effect for Attack 17, where ShaTS clearly localizes the anomaly to process P3.




Fig. 1. Comparison of ShaTS (top) and post-hoc SHAP (bottom) for Attack 17 at the process level. ShaTS localizes the anomaly source to P3, showing a clear band, whereas post-hoc KernelSHAP spreads importance across processes, obscuring the source. Heatmaps plot consecutive windows on the x-axis and feature groups on the left y; each cell (i, j) is the contribution of group j to window i . Warm reds mark positive influence, cool blues negative, and near-zero values are left blank. The purple curve shows the anomaly probability; the horizontal line marks the threshold used to classify a window as anomalous.

As illustrated in Figure 2, ShaTS execution time remains nearly constant as the window size increases, whereas Ker-




Fig. 2. Comparison of mean execution time per window of ShaTS and post hoc SHAP over a batch of 100 windows for different window size AD models

nelSHAP exhibits rapidly growing runtime and often exceeds memory limits due to its per-time-step attribution strategy.

IV. CONCLUSIONS AND OUTLOOK

ShaTS addresses a fundamental limitation of post-hoc Shapley explainers when applied to time series AD in industrial environments. By incorporating temporal and structural grouping directly into the Shapley computation, ShaTS produces explanations that are more coherent, actionable, and computationally viable.

Experimental results on the SWaT testbed demonstrate that ShaTS significantly improves attack localization accuracy while satisfying real-time constraints, making it well suited for deployment in safety-critical IIoT systems. The method assumes the availability of a mapping between model features and physical components, which is a reasonable requirement in most industrial contexts.

Future work includes extending the evaluation to additional datasets and model families, investigating adaptive and data-driven grouping strategies, and broadening comparisons with alternative Shapley-based explainers.

V. ACKNOWLEDGEMENTS

This work has been funded by (a) 22954/FPI/25, Fundación Séneca, co-financed by Scorpion Cybertechnologies, Region of Murcia (Spain); (b) the European Commission through the Horizon Europe/JU SNS project ROBUST-6G (Grant Agreement No. 101139068); and (c) the Swiss Federal Office for Defence Procurement (armasuisse) through the TITAN Project.

REFERENCES

- [1] M. F. De La Peña, Á. L. P. Gómez, and L. F. Maimó, "Shats: A shapley-based explainability method for time series artificial intelligence models," *Future Generation Computer Systems*, p. 108178, 2025.
- [2] S. M. Lundberg and S.-I. Lee, "A unified approach to interpreting model predictions," *arXiv preprint arXiv:1705.07874*, 2017.
- [3] A. P. Mathur and N. O. Tippenhauer, "SWaT: A water treatment testbed for research and training on ICS security," in *2016 International Workshop on Cyber-Physical Systems for Smart Water Networks (CySWater)*. IEEE, 2016, pp. 31–36.

Propuesta de un módulo de xAI con degradación controlada para frameworks de AD

Manuel Franco de la Peña, Ángel Luis Perales Gómez, Lorenzo Fernández Maimó

Departamento de Ingeniería y Tecnología de Computadores

Universidad of Murcia, Espinardo, Murcia, Spain

{manuel.franco, angelluis.perales, lfmaimo}@um.es

Resumen—La explicabilidad es un requisito clave para la adopción de modelos de detección de anomalías en entornos industriales, donde explicaciones tardías pueden impedir mitigar a tiempo un comportamiento anómalo y, por tanto, deben generarse bajo restricciones estrictas sobre el tiempo de respuesta. Los métodos de explicabilidad basados en valores Shapley, aunque ofrecen descomposiciones aditivas consistentes, presentan un coste computacional elevado que limita su uso *online*. En este trabajo se propone IG-ShaTS, una extensión de ShaTS que incorpora un mecanismo de degradación controlada aprovechando la continuidad temporal. El método reutiliza explicaciones calculadas con ShaTS y las actualiza eficientemente mediante un término correctivo basado en Integrated Gradients, preservando una descomposición aditiva. La propuesta se valida en un escenario industrial realista, demostrando que IG-ShaTS permite mantener explicaciones útiles bajo restricciones estrictas sobre el tiempo de respuesta con mejoras significativas de rendimiento computacional.

Index Terms—Explainable Artificial Intelligence, Shapley values, Integrated Gradients, Anomaly Detection, Time Series, Industrial Internet of Things

Tipo de contribución: Investigación en desarrollo

I. INTRODUCCIÓN

La detección de anomalías (AD) es un componente clave en entornos industriales, donde los modelos de ML/DL se emplean para identificar ciberataques a partir de los datos de funcionamiento del sistema [1]. En estos entornos los operadores necesitan comprender qué ha provocado la decisión del modelo para poder mitigar el problema. Por ello, la explicabilidad (xAI) se ha convertido en un requisito práctico para la adopción de estos modelos.

Entre los métodos de xAI más utilizados destacan los basados en valores Shapley [2], ya que proporcionan explicaciones con una interpretación clara: la suma de las contribuciones coincide con la salida del modelo. Sin embargo, el coste computacional de estos métodos es elevado, lo que dificulta su integración *online*.

Este trabajo parte de la premisa de que un módulo de xAI integrado en un sistema industrial debe mantener su disponibilidad bajo restricciones estrictas en el tiempo de respuesta, ya que explicaciones tardías pueden impedir mitigar a tiempo un comportamiento anómalo. En estos escenarios, es preferible ofrecer explicaciones aproximadas antes que no ofrecer ninguna. Esto motiva el desarrollo de mecanismos de degradación controlada (*graceful degradation*), capaces de ajustar la precisión de las explicaciones para mantener la disponibilidad del módulo.

En series temporales existe además una propiedad clave que puede explotarse: la continuidad temporal. Observaciones consecutivas suelen ser similares, por lo que tanto las

predicciones como las explicaciones deberían variar de forma suave [3]. ShaTS [4] supone un avance al adaptar los valores Shapley a series temporales mediante una agrupación *a priori*. No obstante, ShaTS sigue calculando explicaciones completas para cada instancia, sin explotar continuidad temporal para reducir costes.

En este trabajo se propone **IG-ShaTS**, una extensión de ShaTS que incorpora degradación controlada aprovechando la continuidad temporal de las series temporales. IG-ShaTS reutiliza explicaciones calculadas con ShaTS y las actualiza mediante un término correctivo basado en *Integrated Gradients* (IG) [5] cuando la observación actual es suficientemente similar a una anterior. Esta conmutación dinámica entre cálculo completo y aproximado permite adaptar el coste computacional del módulo de xAI a distintos requisitos de latencia. Las contribuciones de este trabajo son:

- **Propuesta e implementación de IG-ShaTS**, una extensión de ShaTS que explota continuidad temporal para reutilizar explicaciones y habilitar degradación controlada en AD sobre series temporales. El método es de código abierto y se encuentra disponible en GitHub¹.
- **Definición de un criterio operativo** basado en la similitud entre observaciones que permite controlar explícitamente el compromiso entre coste computacional y la fidelidad explicativa.
- **Validación del método en un entorno industrial realista** bajo diferentes restricciones de tiempo real utilizando el conjunto de datos WADI [6].

El resto del artículo está estructurado de la siguiente manera: La sección II trata la base teórica, la sección III revisa el estado del arte de la xAI en entornos industriales, en la sección IV se presenta el módulo de xAI propuesto y se integra en un framework de AD, en la sección V se detallan los resultados experimentales y finalmente en la sección VI se discuten las conclusiones y el trabajo futuro.

II. MARCO TEÓRICO

En esta sección se presenta el marco teórico necesario para comprender dos métodos de xAI que serán utilizados posteriormente: los valores Shapley e IG. Dado un modelo de ML/DL representado como una función $f: \mathbb{R}^n \rightarrow \mathbb{R}$ y una instancia concreta $x^* \in \mathbb{R}^n$, el objetivo de estos métodos es obtener un vector de tamaño n que cuantifique la influencia de cada característica de entrada sobre la predicción $f(x^*)$.

¹<https://github.com/CyberDataLab/ShaTS>

II-A. Método de los valores Shapley

El método de los valores Shapley tiene su origen en la teoría de juegos, donde un conjunto de jugadores N coopera para obtener un resultado. En este contexto, se define la función valor de un juego como una aplicación $v : 2^N \rightarrow \mathbb{R}$, que asigna a cada coalición de jugadores $S \subseteq N$ el resultado de su participación conjunta en el juego. A partir de esta función, el valor Shapley de cada jugador $i \in N$, denotado como $\varphi_i(v)$ y calculado mediante la Eq. (1), representa su contribución individual al resultado del juego.

$$\varphi_i(v) = \sum_{S \subseteq N \setminus \{i\}} \frac{|S|! \cdot (|N| - |S| - 1)!}{|N|!} \cdot (v(S \cup \{i\}) - v(S)) \quad (1)$$

Este valor es el único que satisface los axiomas de simetría, aditividad, jugador ficticio y eficiencia [7]. Siendo este último el más característico y estableciendo que la suma de las contribuciones individuales coincide con el valor total del juego, es decir, $\sum_{i \in N} \varphi_i(v) = v(N)$.

En el contexto de la xAI, este método se adapta considerando cada característica de entrada como un jugador y el modelo de ML/DL como el juego cooperativo. Sea x_S^* el subvector de x^* que contiene únicamente las características pertenecientes a la coalición S , y $x_{\bar{S}}^*$ el subvector complementario, la función valor de un modelo f para una coalición S se define como su esperanza condicionada por $x_{\bar{S}}^*$. Sin embargo, dado que esta definición requiere conocer la distribución completa del modelo, en la práctica se aproxima según la Eq. (2) mediante un conjunto de instancias de referencia, denominado conjunto de *background* y denotado $\mathcal{B} = \{b^1, \dots, b^m\} \subset \mathbb{R}^n$.

$$v(S, x^*) \approx \frac{1}{m} \sum_{j=1}^m f(x_S^*, b_{\bar{S}}^j) \quad (2)$$

No obstante, el cálculo exacto del valor Shapley sigue siendo computacionalmente prohibitivo, ya que requiere evaluar 2^n coaliciones para cada característica. Por ello, normalmente se recurre a una aproximación basada en el muestreo de k coaliciones $\{S_1, \dots, S_k\}$. Bajo este enfoque, el valor Shapley aproximado se calcula mediante la Eq. (3).

$$\varphi_i(v, x^*) = \sum_{j=1}^k \frac{|S_j|! \cdot (|N| - |S_j| - 1)!}{|N|!} \cdot (v(S_j \cup \{i\}) - v(S_j)) \quad (3)$$

II-B. Método de Integrated Gradients

El método de IG [5] es un método de atribución basado en gradientes, diseñado para modelos diferenciables con respecto a sus características de entrada. A diferencia del método de los valores Shapley, IG no se apoya en una distribución de referencia, sino en una única instancia *baseline* b^* . IG atribuye a cada característica i su contribución a la diferencia entre la predicción del modelo en la instancia de interés x^* y la predicción correspondiente al *baseline* b^* , denotándose dicha atribución como $IG_i(b^* \rightarrow x^*)$.

Este método satisface los axiomas de sensibilidad, invarianza a la implementación y completitud. Este último asegura que la suma de las atribuciones individuales coincide con la diferencia total de la predicción, es decir, $\sum_{i=1}^n IG_i(b^* \rightarrow x^*) = f(x^*) - f(b^*)$.

La atribución de la característica i mediante IG se define según la Eq. (4), que corresponde a la integral de la derivada parcial del modelo a lo largo del segmento que conecta el *baseline* b^* con la instancia x^* en el espacio de entrada.

$$IG_i(b^* \rightarrow x^*) = (x_i^* - b_i^*) \int_0^1 \frac{\partial f(b^* + \alpha(x^* - b^*))}{\partial x_i} d\alpha \quad (4)$$

Dado que la integral definida en la Eq. (4) no puede calcularse de forma exacta en la práctica, se aproxima mediante una media de L puntos equiespaciados a lo largo del segmento. Esta aproximación, cuya fórmula se muestra en la Eq. (5) convierte el método en un procedimiento con un coste lineal respecto a L .

$$IG_i(b^* \rightarrow x^*) = (x_i^* - b_i^*) \frac{1}{L} \sum_{k=1}^L \frac{\partial f(b^* + \frac{k}{L}(x^* - b^*))}{\partial x_i} \quad (5)$$

III. ESTADO DEL ARTE

Esta sección revisa los trabajos más relevantes en xAI aplicada a AD en entornos industriales, con especial atención a su viabilidad en escenarios operativos con restricciones de tiempo real. En este contexto, se entiende por operación *online* aquella en la que la detección y la explicación deben generarse de forma que no introduzcan latencias incompatibles con el periodo de muestreo. En primer lugar, se analizan los principales métodos de xAI desde una perspectiva estructural. A continuación, se revisan frameworks completos de AD que integran módulos de xAI, identificando limitaciones recurrentes en su integración operativa.

III-A. Métodos de xAI aplicados a entornos industriales

Los métodos de xAI más utilizados en la práctica industrial son de tipo *post-hoc* y explican predicciones individuales sin modificar el modelo subyacente. Entre ellos, SHAP [2] estima contribuciones marginales a partir de una distribución de referencia (denominada conjunto de *background*) y proporciona una descomposición aditiva de la predicción. Esta referencia resulta especialmente deseable en entornos industriales, ya que permite estimar las contribuciones con respecto a una distribución en lugar de a un único valor de referencia, reduciendo la dependencia de elecciones arbitrarias. Sin embargo, SHAP explica cada instancia de forma independiente y no explota el hecho de que instancias cercanas suelen corresponder a estados similares del sistema. Además, su coste computacional limita su uso en escenarios *online*. LIME [8], por su parte, genera explicaciones locales mediante perturbaciones y modelos sustitutos, pero no utiliza una distribución de referencia, no ofrece una descomposición aditiva coherente y tampoco garantiza estabilidad entre explicaciones consecutivas [9].

IG [5] adopta un enfoque distinto, atribuyendo la salida del modelo mediante la integración de gradientes a lo largo de un camino entre una referencia y la instancia explicada. IG presenta limitaciones relevantes en su aplicación sobre series temporales ya que el camino de interpolación puede atravesar regiones fuera de la distribución de los datos. Además IG no reutiliza información explicativa entre observaciones consecutivas, ignorando así su continuidad temporal inherente.

Método	Diseñado para series temporales	Distribución de referencia	Descomposición aditiva	Degradación controlada
SHAP [2]	×	✓	✓	×
LIME [8]	×	×	×	×
IG [5]	×	×	✓	×
ALE [10]	×	✓	×	×
FIT [11]	✓	×	×	×
SEGAL [12]	✓	×	×	×
Dynamask [13]	✓	×	×	×
ShaTS [4]	✓	✓	✓	×
IG-ShaTS	✓	✓	✓	✓

Tabla I
COMPARACIÓN DE MÉTODOS DE EXPLICABILIDAD SEGÚN PROPIEDADES ESTRUCTURALES CLAVE EN AD SOBRE SERIES TEMPORALES.

ALE [10] propone un enfoque basado en efectos acumulados locales condicionados a la distribución de los datos. Si bien se apoya en una distribución de referencia, no está orientado a explicaciones locales aditivas por instancia ni modela explícitamente la estructura temporal de las series.

En respuesta a estas limitaciones, se han propuesto métodos diseñados explícitamente para series temporales, partiendo de la idea de que pequeños cambios en la señal suelen corresponder a pequeños cambios en la predicción. FIT [11] define la importancia de una observación en función de su contribución al cambio de la predicción entre instantes consecutivos, explotando de forma natural esta continuidad temporal. Sin embargo, no proporciona una descomposición aditiva de la salida. SEGAL [12] adapta LIME al contexto temporal mediante perturbaciones que respetan la continuidad de la señal, mejorando la estabilidad local, pero hereda la ausencia de una distribución de referencia y de aditividad. Dynamask [13] introduce máscaras continuas con dependencia temporal explícita, generando explicaciones suaves, aunque sin garantizar una descomposición aditiva formal.

Finalmente, ShaTS [4] permite el uso del método de los valores Shapley con series temporales mediante una estrategia de agrupación *a priori*. ShaTS combina el uso de una distribución de referencia con la descomposición aditiva, produciendo explicaciones alineadas con la semántica industrial. No obstante, calcula explicaciones completas para cada observación de forma independiente, sin explotar la continuidad temporal para reducir el coste computacional.

La Tabla I resume estas propiedades y pone de manifiesto una limitación común: los métodos aditivos clásicos no explotan la continuidad temporal, mientras que los métodos diseñados para series temporales suelen renunciar a una descomposición aditiva.

III-B. Frameworks de AD con módulos de xAI

En frameworks industriales de AD, la explicabilidad suele incorporarse como un módulo *post-hoc* destinado al análisis, y no como un componente integrado en el funcionamiento del sistema. En numerosos trabajos, SHAP se emplea para interpretar modelos de AD [14], [15], [16], pero las explicaciones se calculan de forma diferida, lo que refleja su inviabilidad *online*. Estudios como WaXAI [17] confirman que el coste computacional de estos métodos impide su ejecución continua bajo restricciones de tiempo real.

Este patrón se repite en arquitecturas donde la viabilidad computacional del módulo de xAI no se analiza explícitamente [18], [19]. Incluso en métodos intrínsecamente explicables [20], [21], el énfasis se sitúa en la calidad explicativa, asumiendo implícitamente que el coste computacional excluye su uso en operación continua.

De la revisión anterior se observa que los métodos existentes combinan un coste computacional elevado con la falta de mecanismos adaptativos para ajustar el coste explicativo en operación, lo que conduce a una carencia común: la ausencia de estrategias explícitas de degradación controlada en el módulo de xAI. En particular, ninguno de ellos explota la continuidad temporal como criterio para implementar dicha adaptación. En la mayoría de frameworks, la explicabilidad se concibe como un proceso de coste fijo que, bajo restricciones temporales, se ejecuta de forma diferida. Frente a este enfoque, IG-ShaTS introduce reutilización temporal de explicaciones y conmutación dinámica entre cómputo completo y aproximado, con el objetivo de preservar la disponibilidad explicativa en escenarios operativos con requisitos de tiempo real.

IV. METODOLOGÍA

En esta sección se explica el funcionamiento de IG-ShaTS y su integración como módulo xAI en un framework de AD con restricciones en el tiempo de respuesta. IG-ShaTS incorpora un componente de degradación controlada que explota la continuidad temporal y permite adaptar dinámicamente el coste computacional.

IV-A. Framework de AD

A lo largo de esta sección se describe un framework típico de AD compuesto por tres módulos: preprocesamiento, predicción y xAI. Además, se asume la disponibilidad de tres conjuntos de datos secuenciales previamente recopilados y segmentados de forma que respeten la estructura temporal del sistema y minimicen la correlación entre sus límites: los conjuntos de entrenamiento y validación, empleados durante la construcción del framework o fase *offline*, y el de test, reservado para evaluar el comportamiento y la viabilidad en la fase *online*.

IV-A1. Módulo de preprocesamiento de datos: El módulo de preprocesamiento tiene como objetivo preparar los datos para el formato esperado por el modelo de predicción. Durante su construcción en la fase *offline*, en primer lugar, se definen criterios de limpieza orientados a mitigar las irregularidades propias de entornos industriales. Dado el carácter secuencial de los datos, las observaciones se organizan en ventanas temporales que permiten al módulo de predicción mejorar su rendimiento mediante la captura de la evolución del sistema. El tamaño de ventana determina el horizonte temporal observado, mientras que el *stride* controla la frecuencia de generación de nuevas instancias. Las características que representan mediciones continuas se normalizan y las categóricas se codifican mediante *one-hot encoding*. Además, se eliminan características con varianza nula. Todos los estadísticos necesarios para estas transformaciones se estiman exclusivamente sobre el conjunto de entrenamiento.

En la fase *online*, el trabajo de este módulo se reduce a la aplicación directa de las transformaciones aprendidas, garantizando un coste computacional bajo.

IV-A2. Módulo de predicción: El módulo de predicción es responsable de la ejecución del modelo de ML/DL que realiza la tarea de detección.

Para su construcción durante la fase *offline*, en primer lugar se debe seleccionar un tipo de modelo con capacidad para capturar relaciones temporales, dado que este tipo de dependencias resultan críticas para mejorar el rendimiento en entornos industriales. Arquitecturas recurrentes como las redes neuronales LSTM son especialmente adecuadas para este propósito. A continuación, se realiza una búsqueda de hiperparámetros para optimizar el rendimiento del modelo. Una vez fijada la configuración final, el modelo se evalúa mediante métricas estándar de AD, destacando el F1-score, que asegura un equilibrio entre detección de eventos anómalos y control de falsas alarmas.

En la fase *online*, este módulo genera para cada ventana una probabilidad de anomalía, cuyo coste computacional es generalmente reducido.

IV-A3. Módulo de xAI (ShaTS): El módulo de xAI recibe la ventana de entrada y la predicción del modelo, y descompone dicha predicción en un vector de importancias. Se describirá primero el funcionamiento base del método de ShaTS para posteriormente explicar la propuesta de adaptación de este trabajo para que cumpla con las restricciones operacionales de latencia.

ShaTS proporciona explicaciones basadas en valores Shapley para modelos que operan sobre ventanas temporales. Un aspecto diferencial de ShaTS es su enfoque de agrupación *a priori*: en lugar de tratar cada característica en cada instante temporal de forma independiente, define grupos semánticamente significativos. Se considera $x \in \mathbb{R}^{n \cdot w}$ una ventana de n características y tamaño w donde cada componente x_j representa una dimensión individual del vector de entrada asociada a una característica concreta en un instante temporal. Sea entonces $\mathcal{G} = \{G_1, \dots, G_m\}$ una partición de sus $n \cdot w$ dimensiones en m grupos, donde cada grupo G_i es un subconjunto de dimensiones que agrupa variables temporal o semánticamente relacionadas, las atribuciones se calculan directamente sobre $\mathcal{G}$. ShaTS soporta diferentes estrategias de agrupación que permiten adaptar el nivel de granularidad de la explicación: *temporal*, *feature* y *multifeature*. Para su construcción, además de la estrategia de agrupación, ShaTS requiere un conjunto de *background* muestreado del conjunto de entrenamiento, utilizado como distribución de referencia para estimar los valores faltantes en cada coalición. Por último, se selecciona un algoritmo de cómputo, que puede ser exacto con complejidad $O(2^m)$ o aproximado con complejidad $O(m^2)$.

En la fase *online*, este módulo constituye el principal cuello de botella computacional del framework, ya que requiere múltiples evaluaciones del modelo para estimar las contribuciones de los distintos grupos para cada instancia. En escenarios de alta frecuencia de muestreo, este coste puede resultar incompatible con los requisitos de tiempo real, motivando la necesidad de un mecanismo de adaptación dinámica.




Figura 1. Explotación de la continuidad temporal para la reutilización de explicaciones mediante IG-ShaTS.

IV-B. Extensión de ShaTS con IG: Propuesta de IG-ShaTS

En entornos industriales sometidos a restricciones estrictas en el tiempo de respuesta, es preferible disponer de explicaciones aproximadas antes que no disponer de explicaciones en absoluto. Esta observación motiva la introducción de un mecanismo de degradación controlada que, además, explote la continuidad temporal. La hipótesis de trabajo es que las explicaciones correspondientes a ventanas cercanas en el tiempo tienden a ser similares, salvo en situaciones de cambio abrupto del estado del sistema.

La propuesta consiste en mantener el cálculo completo de ShaTS de forma periódica sobre una ventana de referencia, denominada ventana *ancla*. Para ventanas posteriores, si estas son suficientemente similares a la ventana ancla, la explicación se aproxima reutilizando la explicación previa y añadiendo un término correctivo basado en el método de IG, que modela el cambio entre ambas. La idea de continuidad explicativa y su explotación para aproximar explicaciones se ilustran conceptualmente en la Fig. 1.

Sea x^t la ventana ancla y x^{t+h} una ventana posterior, la explicación aproximada de IG-ShaTS se define mediante la Eq. (7), donde $IG_{G_i}(x^t \rightarrow x^{t+h})$ representa la contribución del grupo G_i a lo largo del camino que conecta ambas ventanas.

$$IG_{G_i}(x^t \rightarrow x^{t+h}) = \sum_{j \in G_i} IG_j(x^t \rightarrow x^{t+h}) \quad (6)$$

En la práctica, para calcular este valor se debe calcular primero el valor IG de cada característica y posteriormente agregarlas mediante la Eq. (6). Esta igualdad se fundamenta en la linealidad de la integral y del operador gradiente, ya que la integral de una suma de gradientes coincide con la suma de sus integrales, garantizando que la atribución IG de un grupo es la suma de las atribuciones de sus dimensiones.

$$ShaTS-IG_{G_i}(x^{t+h}) = ShaTS_{G_i}(x^t) + IG_{G_i}(x^t \rightarrow x^{t+h}) \quad (7)$$

Cada término $IG_j(x^t \rightarrow x^{t+h})$, se calcula según la Eq. (8), aproximando la integral mediante una suma con L pasos sobre el segmento entre x^t y x^{t+h} . En el caso de características categóricas codificadas mediante *one-hot encoding*, si no hay cambio entre x_j^t y x_j^{t+h} el término IG es nulo, mientras que si existe transición binaria, el camino de integración se construye de forma discreta manteniendo el valor inicial durante la primera mitad del recorrido y el final durante la segunda.

$$\text{IG}_j(x^t \rightarrow x^{t+h}) = (x_j^{t+h} - x_j^t) \frac{1}{L} \sum_{k=1}^L \frac{\partial f(x^t + \frac{k}{L}(x^{t+h} - x^t))}{\partial x_j} \quad (8)$$

Además, dado que IG satisface el axioma de completitud, la suma de contribuciones a lo largo de todas las características (y, por ende, de todos los grupos) recupera la diferencia de salida del modelo, como recoge la Eq. (9). A su vez, dado que ShaTS cumple el axioma de eficiencia, expresado en la Eq. (10), la combinación definida en la Eq. (7) preserva la eficiencia total en x^{t+h} , como formaliza la Eq. (11). Esta propiedad es especialmente relevante porque mantiene una interpretación consistente del vector de importancias como descomposición aditiva de la predicción.

$$\sum_{j=1}^n \text{IG}_j(x^t \rightarrow x^{t+h}) = f(x^{t+h}) - f(x^t) \quad (9)$$

$$\sum_{G_i \in \mathcal{G}} \text{ShaTS}_{G_i}(x^t) = f(x^t) \quad (10)$$

$$\sum_{G_i \in \mathcal{G}} \text{ShaTS-IG}_{G_i}(x^{t+h}) = f(x^{t+h}) \quad (11)$$

El criterio para decidir entre un cálculo completo de ShaTS o una aproximación mediante IG se basa en el coste computacional esperado del módulo de xAI. Sea t_{ShaTS} el tiempo de cómputo de un cálculo completo, t_{IG} el tiempo necesario para calcular IG (con $t_{\text{IG}} \ll t_{\text{ShaTS}}$) y $p \in [0, 1]$ la probabilidad de poder utilizar una aproximación, el tiempo esperado del módulo de xAI queda caracterizado por la Eq. (12).

$$\mathbb{E}[T_{\text{xAI}}] = p t_{\text{IG}} + (1 - p) t_{\text{ShaTS}}. \quad (12)$$

Sea T_s el periodo de muestreo del sistema, T_{rest} el tiempo consumido por los módulos de preprocesamiento y detección en fase *online*, se requiere entonces que el tiempo esperado del módulo de xAI no exceda el tiempo disponible, lo cual se expresa en la Eq. (13). A partir de dicha condición, se obtiene una cota inferior para p que garantice este cumplimiento, formalizada en la Eq. (14).

$$\mathbb{E}[T_{\text{xAI}}] \leq T_s - T_{\text{rest}} \quad (13)$$

$$p \geq \frac{t_{\text{ShaTS}} - (T_s - T_{\text{rest}})}{t_{\text{ShaTS}} - t_{\text{IG}}} \quad (14)$$

Una estrategia basada únicamente en imponer una proporción fija de aproximaciones resulta poco robusta, ya que ignora la dinámica real del sistema. Para evitarlo, se define un criterio adaptativo basado en la similitud entre ventanas. En la fase *offline*, se calcula la distribución de distancias entre ventanas consecutivas sobre el conjunto de entrenamiento y se fija un percentil $q \in [0, 100]$, cuyo valor asociado τ_q deja por debajo al $q\%$ de las distancias observadas. En la fase *online*, si la distancia entre la ventana actual y la ventana ancla es inferior a τ_q , se reutiliza la explicación mediante IG-ShaTS; en caso contrario, se recalcula ShaTS y se actualiza la ventana ancla. Este recalclo es necesario porque la actualización mediante IG es una aproximación local válida solo en vecindades similares; de lo contrario, el error podría

Tabla II
PARRILLA DE HIPERPARÁMETROS EMPLEADA EN EL ENTRENAMIENTO DEL MODELO LSTM, INDICANDO EN NEGRITA LOS VALORES SELECCIONADOS

Hiperparámetro	Valores evaluados
Tamaño oculto	{32, 64 , 128}
Número de capas	{1, 2 , 3, 5}
Dropout	{0.0, 0.05, 0.1 , 0.2}
Weight decay	{0.0, 0.0001 , 0.001, 0.01}

acumularse progresivamente. El umbral τ_q actúa así como un criterio de reinicio que limita dicha acumulación. Bajo el supuesto de que la dinámica en operación sea comparable a la de entrenamiento, el percentil q induce una probabilidad de reutilización $p \approx q/100$, actuando así como un parámetro que ajusta el grado de degradación permitido.

V. RESULTADOS EXPERIMENTALES

En esta sección se evalúa la propuesta *IG-ShaTS* como mecanismo de degradación controlada para explicabilidad *online* en un framework de AD. El objetivo no es únicamente medir la calidad explicativa, sino caracterizar explícitamente el compromiso entre la calidad y el coste al reutilizar explicaciones entre ventanas cercanas en el tiempo, explotando la continuidad temporal discutida en la Sección III.

Los experimentos se ejecutaron en una estación de trabajo con CPU Intel® Core™ i7-14700K (28 núcleos) y GPU NVIDIA GeForce RTX 4080 (16GB) sobre CUDA 12.0.140.

V-A. Creación del framework de AD

V-A1. Conjunto de datos utilizado: Se empleó el conjunto de datos WADI [6], que modela una red de distribución de agua muestreada a 1Hz, representada por 123 características y donde se introducen 14 ataques diferentes. Para hacer la división en entrenamiento, validación y test, el conjunto de datos completo se segmentó en bloques de 1000 instancias y, dentro de cada bloque, se asignó el 70 % inicial a entrenamiento, el 15 % a validación y el 15 % a test, introduciendo un *padding* de 50 instantes entre particiones para evitar la fuga de información.

V-A2. Módulo de preprocesamiento de datos: Se eliminaron 27 características con varianza nula y se identificaron 30 características categóricas y 66 continuas. Tras los procesos de *one-hot encoding* y normalización, el conjunto procesado estaba formado por 139 características. Se seleccionó un tamaño de ventana $w = 10$ y para simular operación *online* un *stride* de 1.

V-A3. Módulo de predicción: El detector se implementó con una red LSTM que produce una probabilidad de anomalía por ventana. En fase *offline* se realizó una búsqueda de hiperparámetros sobre el conjunto de validación (Tabla II), seleccionando finalmente una arquitectura de 2 capas y tamaño oculto 64, con *dropout* 0.1 y *weight decay* 10^{-4} , entrenada durante 8 épocas con *batch size* 256. Sobre el conjunto de test se obtuvo F1-score de 0.9869, lo que indica que el módulo de detección ofrece una base sólida para evaluar el módulo de xAI.

V-A4. Módulo de xAI: IG-ShaTS: Tras el entrenamiento del modelo, se integró el módulo explicativo IG-ShaTS. Se adoptó una agrupación *multifeature* donde se creó un grupo

por cada característica continua y un grupo por cada conjunto de variables *one-hot* asociadas a la misma categoría, resultando en un total de 96 grupos, que representan unidades físicas del sistema industrial. Se utilizó un *background* de 200 ventanas muestreadas de forma estratificada según su condición normal/anómala, y se seleccionó el algoritmo aproximado de ShaTS, de complejidad polinómica sobre el número de grupos. Para la selección del parámetro de degradación controlada p se realizaron diversos experimentos sobre diferentes entornos descritos a continuación.

V-B. Diseño experimental

Con el objetivo de evaluar IG-ShaTS como mecanismo de degradación controlada bajo restricciones *online*, se plantean dos experimentos complementarios: (i) una cuantificación global del compromiso entre coste computacional y calidad explicativa al aumentar la reutilización, y (ii) un análisis orientado a operación, fijando restricciones sobre el tiempo de respuesta y evaluando su impacto sobre la explicación de cada ataque.

V-B1. Experimento 1: compromiso entre calidad y coste al aumentar reutilización: En este experimento se comparó el método base (ShaTS) con configuraciones crecientes de reutilización. Operativamente, la reutilización se controla mediante percentiles $q \in \{10, 20, 30, 40, 50, 60, 70, 80, 90, 95, 97, 98, 99\}$, que inducen umbrales de similitud τ_q y, por tanto, distintas probabilidades efectivas de reutilización. Para cada valor de q se evaluó el impacto sobre la similitud explicativa y el coste computacional.

La similitud entre explicaciones se midió, en primer lugar, mediante la correlación de Spearman, que evalúa la estabilidad del orden relativo de importancia entre grupos, donde cada uno está asociado a un sensor físico. Dadas dos explicaciones $a, b \in \mathbb{R}^{|G|}$, la correlación de Spearman se define según la Eq. 15 donde $r(\cdot)$ transforma los valores en rangos.

$$\rho(a, b) = \frac{\text{cov}(r(a), r(b))}{\sigma_{r(a)} \sigma_{r(b)}} \quad (15)$$

De forma complementaria, se evaluó el solapamiento entre los grupos más relevantes mediante la similitud Top-5 de Jaccard según la Eq. (16).

$$J_5(a, b) = \frac{|\text{Top}_5(a) \cap \text{Top}_5(b)|}{|\text{Top}_5(a) \cup \text{Top}_5(b)|} \quad (16)$$

Finalmente se cuantificó el *speedup*, definido como el cociente entre el tiempo medio del método base y el tiempo medio de IG-ShaTS según la Eq. (17).

$$S = \frac{t_{\text{ShaTS}}}{\mathbb{E}[T_{\text{xAI}}]} = \frac{t_{\text{ShaTS}}}{p t_{\text{IG}} + (1 - p) t_{\text{ShaTS}}} \quad (17)$$

Todas estas métricas se calcularon para cada ventana del conjunto de validación. Para estimar intervalos de confianza al 95 %, se empleó la técnica de *bootstrap* con 1000 remuestreos y $\alpha = 0,05$, tomando los percentiles $\alpha/2$ y $1 - \alpha/2$ de la distribución empírica de la media sobre el conjunto de validación. Finalmente se evaluaron las métricas también en el conjunto de test.

Los resultados agregados se muestran en las Figuras 2, 3 y 4. En términos globales, se observa el comportamiento esperado: al aumentar q se incrementa la reutilización y el *speedup*,




Figura 2. Similitud Top-5 (Jaccard) entre las explicaciones base (ShaTS) y aproximadas (IG-ShaTS) en función del percentil q , que controla el grado de reutilización explicativa.




Figura 3. Correlación de Spearman entre las explicaciones base (ShaTS) y aproximadas (IG-ShaTS) en función del percentil q , que controla el grado de reutilización explicativa.

mientras que la similitud con la explicación base se degrada de forma progresiva. Además, las métricas presentan valores muy similares en validación y test, lo que sugiere que el control mediante percentiles captura propiedades temporales estables del sistema.

V-B2. Experimento 2: explicación por ataque bajo restricciones temporales: En este experimento se fijaron distintas restricciones sobre el tiempo de respuesta y se estimó, para cada una de ellas, el grado mínimo de reutilización explicativa necesario para satisfacerlas. Se estimaron sobre el conjunto de validación los tiempos medios de ejecución de cada módulo, obteniendo $t_{\text{ShaTS}} \approx 1,3$ s, mientras que t_{IG} y T_{rest} resultaron despreciables en comparación. Entonces, para $T_s \in \{1, 0,5, 0,25, 0,1\}$ s se calcularon los porcentajes mínimos de reutilización según la cota de la Eq. (14), obteniendo $p \approx \{0,23, 0,62, 0,81, 0,99\}$.

Para cada ataque, se agregaron las explicaciones por ventana del conjunto de test promediando la contribución de cada grupo sobre todas las ventanas del ataque; después se normalizaron y se reportó el Top-5 porcentual. La Tabla III muestra los grupos responsables para el método base y para los niveles de degradación asociados a $T_s = 1$ s, $T_s = 0,5$ s, $T_s = 0,25$ s y $T_s = 0,1$ s. Se observa que, para la mayoría de ataques,




Figura 4. Speedup entre el tiempo de ejecución del método base (ShaTS) y el aproximado (IG-ShaTS) en función del percentil q , que controla el grado de reutilización explicativa.

los grupos dominantes del método base se preservan bajo reutilización moderada ($T_s = 1s, T_s = 0,5s$), con variaciones principalmente en el peso relativo. En cambio, al imponer restricciones más elevadas ($T_s = 0,1s$) aparecen cambios más acusados, indicando que con estos parámetros de degradación, el módulo produce explicaciones que difieren más respecto a las del método base.

VI. CONCLUSIONES Y VÍAS FUTURAS

En este trabajo se ha presentado IG-ShaTS, un método de xAI para frameworks de AD en series temporales que introduce degradación controlada explotando la continuidad temporal. La propuesta combina ShaTS con un término correctivo basado en el método de IG, permitiendo adaptar dinámicamente el tiempo de respuesta del módulo de xAI en escenarios *online*.

Los resultados experimentales en un entorno industrial realista muestran que IG-ShaTS logra mejoras significativas de rendimiento computacional con una degradación controlada de la calidad explicativa. En rangos intermedios de reutilización, se preservan el orden relativo de importancia y los principales grupos responsables de cada ataque, haciendo viable su integración.

Como principal limitación, IG-ShaTS requiere modelos diferenciables, pues su término correctivo se basa en gradientes. Como trabajo futuro, se plantea extender el método mediante aproximaciones al gradiente o modelos sustitutos, así como estudiar criterios de similitud más avanzados y mecanismos que ajusten el grado de reutilización según el contexto operativo.

VII. AGRADECIMIENTOS

Este trabajo ha sido financiado por (a) 22954/FPI/25, Fundación Séneca, cofinanciado por Scorpion Cybertechnologies, Región de Murcia (Spain); (b) the European Commission a través del proyecto Horizon Europe/JU SNS ROBUST-6G (Grant Agreement No. 101139068); y (c) the Swiss Federal Office for Defense Procurement (armasuisse) a través del TITAN Project.

REFERENCIAS

- [1] K. E. Hemsley, E. Fisher *et al.*, "History of industrial control system cyber incidents," Idaho National Lab.(INL), Idaho Falls, ID (United States), Tech. Rep., 2018.
- [2] S. M. Lundberg and S.-I. Lee, "A unified approach to interpreting model predictions," *Advances in neural information processing systems*, vol. 30, 2017.
- [3] M. Nauta, J. Trienes, S. Pathak, E. Nguyen, M. Peters, Y. Schmitt, J. Schlötterer, M. Van Keulen, and C. Seifert, "From anecdotal evidence to quantitative evaluation methods: A systematic review on evaluating explainable ai," *ACM Computing Surveys*, vol. 55, no. 13s, pp. 1–42, 2023.
- [4] M. F. De La Peña, Á. L. P. Gómez, and L. F. Maimó, "Shats: A shapley-based explainability method for time series artificial intelligence models," *Future Generation Computer Systems*, p. 108178, 2025.
- [5] M. Sundararajan, A. Taly, and Q. Yan, "Axiomatic attribution for deep networks," in *International conference on machine learning*. PMLR, 2017, pp. 3319–3328.
- [6] C. M. Ahmed, V. R. Palleti, and A. P. Mathur, "Wadi: a water distribution testbed for research in the design of secure cyber physical systems," in *Proceedings of the 3rd international workshop on cyber-physical systems for smart water networks*, 2017, pp. 25–28.
- [7] L. Shapley, *A Value for n -Person Games*. Princeton: Princeton University Press, 1953, pp. 307–317. [Online]. Available: <https://doi.org/10.1515/9781400881970-018>
- [8] M. T. Ribeiro, S. Singh, and C. Guestrin, "why should i trust you? explaining the predictions of any classifier," in *Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining*, 2016, pp. 1135–1144.
- [9] D. Alvarez-Melis and T. S. Jaakkola, "On the robustness of interpretability methods," *arXiv preprint arXiv:1806.08049*, 2018.
- [10] D. W. Apley and J. Zhu, "Visualizing the effects of predictor variables in black box supervised learning models," *Journal of the Royal Statistical Society Series B: Statistical Methodology*, vol. 82, no. 4, pp. 1059–1086, 2020.
- [11] S. Tonekaboni, S. Joshi, K. Campbell, D. K. Duvenaud, and A. Goldenberg, "What went wrong and when? instance-wise feature importance for time-series black-box models," *Advances in Neural Information Processing Systems*, vol. 33, pp. 799–809, 2020.
- [12] H. Meng, C. Wagner, and I. Triguero, "Segal time series classification—stable explanations using a generative model and an adaptive weighting method for lime," *Neural Networks*, vol. 176, p. 106345, 2024.
- [13] J. Crabbé and M. Van Der Schaar, "Explaining time series predictions with dynamic masks," in *International Conference on Machine Learning*. PMLR, 2021, pp. 2166–2177.
- [14] L. C. Brito, G. A. Susto, J. N. Brito, and M. A. Duarte, "An explainable artificial intelligence approach for unsupervised fault detection and diagnosis in rotating machinery," *Mechanical Systems and Signal Processing*, vol. 163, p. 108105, 2022.
- [15] T. T. Huong, T. P. Bac, K. N. Ha, N. V. Hoang, N. X. Hoang, N. T. Hung, and K. P. Tran, "Federated learning-based explainable anomaly detection for industrial control systems," *IEEE Access*, vol. 10, pp. 53 854–53 872, 2022.
- [16] E. Brusa, L. Cibrario, C. Delprete, and L. G. Di Maggio, "Explainable AI for machine fault diagnosis: Understanding features' contribution in machine learning models for industrial condition monitoring," *Applied Sciences*, vol. 13, no. 4, p. 2038, 2023.
- [17] K. Mathuros, S. Venugopalan, and S. Adepu, "Waxai: Explainable anomaly detection in industrial control systems and water systems," in *Proceedings of the 10th ACM Cyber-Physical System Security Workshop*, 2024, pp. 3–15.
- [18] N. X. Hoang, N. V. Hoang, N. H. Du, T. T. Huong, K. P. Tran *et al.*, "Explainable anomaly detection for industrial control system cybersecurity," *IFAC-PapersOnLine*, vol. 55, no. 10, pp. 1183–1188, 2022.
- [19] C. Hwang and T. Lee, "E-SFD: Explainable sensor fault detection in the ICS anomaly detection system," *IEEE Access*, vol. 9, pp. 140 470–140 486, 2021.
- [20] C. Tang, L. Xu, B. Yang, Y. Tang, and D. Zhao, "GRU-based interpretable multivariate time series anomaly detection in industrial control systems," *Computers & Security*, vol. 127, p. 103094, 2023.
- [21] Á. L. Perales Gómez, L. Fernández Maimó, A. Huertas Celdrán, and F. J. García Clemente, "An interpretable semi-supervised system for detecting cyberattacks using anomaly detection in industrial scenarios," *IET Information Security*, vol. 17, no. 4, pp. 553–566, 2023.

Ataque	ShaTS base	$T_s = 1s$	$T_s = 0,5s$	$T_s = 0,25s$	$T_s = 0,1s$
0	1_FIT_001_PV (54 %)	1_FIT_001_PV (71 %)	1_FIT_001_PV (45 %)	1_FIT_001_PV (21 %)	1_FIT_001_PV (53 %)
	3_FIT_001_PV (17 %)	3_FIT_001_PV (23 %)	1_MV_001_ST (15 %)	3_FIT_001_PV (13 %)	1_MV_001_ST (29 %)
	1_MV_001_ST (15 %)	1_MV_001_ST (21 %)	3_FIT_001_PV (15 %)	1_MV_001_ST (13 %)	1_P_003_ST (13 %)
	1_P_003_ST (9 %)	1_P_003_ST (15 %)	1_P_003_ST (13 %)	1_P_003_ST (13 %)	2_MV_003_ST (9 %)
	1_P_001_ST (8 %)	1_P_001_ST (12 %)	1_P_001_ST (9 %)	1_P_001_ST (12 %)	1_P_001_ST (7 %)
1	1_FIT_001_PV (41 %)	1_FIT_001_PV (41 %)	1_FIT_001_PV (41 %)	1_FIT_001_PV (43 %)	1_FIT_001_PV (60 %)
	2_FIC_501_SP (21 %)	2_FIC_501_SP (20 %)	2_FIC_501_SP (22 %)	2_FIC_501_SP (20 %)	2_FIT_001_PV (10 %)
	1_P_003_ST (9 %)	1_P_003_ST (9 %)	1_P_003_ST (9 %)	1_P_003_ST (10 %)	1_P_001_ST (10 %)
	1_P_001_ST (7 %)	1_P_001_ST (7 %)	1_P_001_ST (9 %)	1_P_001_ST (7 %)	1_P_003_ST (8 %)
	2_FIT_001_PV (6 %)	2_FIT_001_PV (6 %)	2_FIT_001_PV (6 %)	2B_AIT_001_PV (7 %)	2_FQ_101_PV (7 %)
2	2_FIC_501_SP (22 %)	2_FIC_501_SP (23 %)	2_FIC_501_SP (22 %)	2_FIC_501_SP (43 %)	1_FIT_001_PV (46 %)
	1_FIT_001_PV (18 %)	1_FIT_001_PV (19 %)	1_FIT_001_PV (18 %)	1_FIT_001_PV (24 %)	2_FIC_501_SP (31 %)
	1_AIT_001_PV (16 %)	1_AIT_001_PV (17 %)	1_AIT_001_PV (16 %)	1_AIT_001_PV (11 %)	2_FQ_201_PV (9 %)
	2_PIT_001_PV (10 %)	2_PIT_001_PV (9 %)	2_PIT_001_PV (9 %)	2_PIC_003_CO (4 %)	TOTAL_CONS (5 %)
	2_PIC_003_CO (7 %)	2_PIC_003_CO (7 %)	2_PIC_003_CO (7 %)	2_FIC_401_SP (4 %)	2_FIC_201_PV (4 %)
3	1_FIT_001_PV (22 %)	1_FIT_001_PV (21 %)	1_FIT_001_PV (17 %)	2_LT_002_PV (15 %)	2_MCV_301_CO (30 %)
	2_FIC_501_SP (16 %)	2_FIC_501_SP (17 %)	2_FIC_501_SP (15 %)	1_FIT_001_PV (13 %)	2_MCV_401_CO (19 %)
	2_PIT_001_PV (14 %)	2_LT_002_PV (14 %)	2_LT_002_PV (12 %)	2_FIC_501_SP (12 %)	2_MCV_501_CO (15 %)
	2_LT_002_PV (14 %)	2_PIT_001_PV (14 %)	2_PIT_001_PV (11 %)	2_PIT_001_PV (11 %)	2_MCV_201_CO (10 %)
	2_MCV_401_CO (7 %)	3_FIT_001_PV (7 %)	2A_AIT_002_PV (9 %)	2A_AIT_002_PV (10 %)	2_FIC_201_CO (10 %)
4	3_LT_001_PV (34 %)	3_LT_001_PV (33 %)	3_LT_001_PV (36 %)	3_LT_001_PV (34 %)	2_FIC_101_PV (35 %)
	2_FIC_501_SP (32 %)	2_FIC_501_SP (29 %)	2_FIC_501_SP (34 %)	2_FIC_501_SP (20 %)	2_FQ_101_PV (35 %)
	2_LT_002_PV (7 %)	2_LT_002_PV (7 %)	2_LT_002_PV (10 %)	3_AIT_003_PV (15 %)	2_FIC_201_PV (10 %)
	2_MV_401_ST (7 %)	2_MV_401_ST (6 %)	2_MV_401_ST (7 %)	2_LT_002_PV (12 %)	2_PIC_003_PV (10 %)
	2A_AIT_001_PV (6 %)	2A_AIT_001_PV (6 %)	2A_AIT_001_PV (7 %)	3_AIT_004_PV (9 %)	2_PIT_003_PV (8 %)
5	1_AIT_002_PV (56 %)	1_AIT_002_PV (58 %)	1_AIT_002_PV (43 %)	1_FIT_001_PV (33 %)	1_FIT_001_PV (44 %)
	1_FIT_001_PV (20 %)	1_FIT_001_PV (22 %)	1_FIT_001_PV (28 %)	2_FIT_001_PV (16 %)	2_FIT_001_PV (25 %)
	2_FIT_001_PV (13 %)	2_FIC_501_SP (11 %)	2_FIC_501_SP (13 %)	1_AIT_002_PV (10 %)	1_AIT_002_PV (11 %)
	2_FIC_501_SP (9 %)	2_FIT_001_PV (9 %)	2_FIT_001_PV (11 %)	1_P_003_ST (9 %)	1_P_003_ST (10 %)
	1_P_003_ST (5 %)	1_P_003_ST (5 %)	1_P_003_ST (8 %)	1_P_001_ST (7 %)	1_P_001_ST (9 %)
6	2_MCV_007_CO (95 %)	2_MCV_007_CO (95 %)	2_MCV_007_CO (93 %)	2_MCV_007_CO (93 %)	2_MCV_007_CO (90 %)
	2_FIC_601_SP (1 %)	2_FIC_601_SP (1 %)	2_FIC_601_SP (2 %)	2_FIC_601_SP (2 %)	2_FIC_601_SP (2 %)
	2_FIC_501_SP (1 %)	2_FIC_501_SP (1 %)	2_FIC_501_SP (1 %)	2_FIC_501_SP (1 %)	2_FIC_501_SP (2 %)
	2_MCV_501_CO (1 %)	2_MCV_501_CO (1 %)	2_MCV_501_CO (1 %)	3_LT_001_PV (1 %)	3_AIT_003_PV (1 %)
	3_LT_001_PV (1 %)	3_LT_001_PV (1 %)	3_AIT_004_PV (1 %)	2_MCV_501_CO (1 %)	2A_AIT_001_PV (1 %)
7	2A_AIT_004_PV (54 %)	2A_AIT_004_PV (58 %)	3_LT_001_PV (82 %)	3_LT_001_PV (82 %)	3_LT_001_PV (82 %)
	3_LT_001_PV (16 %)	3_LT_001_PV (15 %)	3_AIT_004_PV (6 %)	3_AIT_004_PV (6 %)	3_AIT_004_PV (6 %)
	2_MCV_501_CO (14 %)	2_MCV_501_CO (13 %)	2A_AIT_004_PV (4 %)	2A_AIT_004_PV (4 %)	2A_AIT_004_PV (4 %)
	2A_AIT_001_PV (12 %)	2A_AIT_001_PV (11 %)	2_MCV_501_CO (3 %)	2_MCV_501_CO (2 %)	2_MCV_501_CO (1 %)
	2_FIC_401_CO (6 %)	2_FIC_401_CO (8 %)	2_FIC_401_CO (2 %)	2_FIC_401_CO (2 %)	2_FIC_401_CO (1 %)
8	2_FIC_501_SP (26 %)	2_MCV_601_CO (22 %)	2_MCV_601_CO (21 %)	2_MV_003_ST (55 %)	2_MV_003_ST (58 %)
	2_FIC_601_SP (21 %)	1_LT_001_PV (21 %)	1_LT_001_PV (9 %)	1_P_005_ST (15 %)	1_P_005_ST (15 %)
	2A_AIT_004_PV (14 %)	3_FIT_001_PV (18 %)	3_FIT_001_PV (9 %)	1_P_006_ST (7 %)	1_P_006_ST (7 %)
	2_FIT_201_PV (11 %)	2_P_004_SPEED (17 %)	2_P_004_SPEED (8 %)	2_MCV_601_CO (6 %)	2_MCV_601_CO (6 %)
	1_AIT_001_PV (6 %)	1_AIT_005_PV (17 %)	1_AIT_005_PV (7 %)	2_FIT_002_PV (5 %)	2_FIT_002_PV (5 %)
9	2_FIC_301_PV (22 %)	2_FIC_301_PV (19 %)	1_MV_001_ST (23 %)	1_MV_001_ST (56 %)	1_MV_001_ST (68 %)
	2_FIC_501_SP (21 %)	2_FIC_501_SP (19 %)	2_PIC_003_CO (22 %)	2_FIC_301_PV (15 %)	1_P_001_ST (12 %)
	2_PIC_003_CO (18 %)	2_PIC_003_CO (16 %)	2_FIC_501_SP (21 %)	2B_AIT_004_PV (14 %)	2B_AIT_004_PV (11 %)
	2_P_004_SPEED (16 %)	1_MV_001_ST (16 %)	2_FIC_301_PV (11 %)	2_P_004_SPEED (11 %)	1_P_003_ST (7 %)
	3_FIT_001_PV (13 %)	2_P_004_SPEED (15 %)	2_FIT_001_PV (8 %)	2_MV_003_ST (6 %)	2_FIC_301_PV (2 %)
10	2_MCV_007_CO (93 %)	2_MCV_007_CO (92 %)	2_MCV_007_CO (91 %)	2_MCV_007_CO (91 %)	2_MCV_007_CO (81 %)
	2_MCV_401_CO (1 %)	2_MCV_401_CO (2 %)	2A_AIT_004_PV (2 %)	2A_AIT_004_PV (2 %)	2_MCV_401_CO (9 %)
	1_FIT_001_PV (1 %)	1_FIT_001_PV (1 %)	2_MCV_601_CO (1 %)	2_MCV_601_CO (2 %)	1_FIT_001_PV (2 %)
	1_AIT_001_PV (1 %)	2A_AIT_004_PV (1 %)	2_MCV_601_CO (1 %)	2_FIC_501_SP (1 %)	2_MCV_201_CO (1 %)
	2_FIC_501_SP (1 %)	2_FIC_501_SP (1 %)	1_FIT_001_PV (1 %)	2_MCV_401_CO (1 %)	2_FIC_501_SP (1 %)
11	2_MCV_007_CO (81 %)	2_MCV_007_CO (87 %)	2_MCV_007_CO (87 %)	2_MCV_007_CO (84 %)	2_MCV_007_CO (94 %)
	1_FIT_001_PV (6 %)	1_FIT_001_PV (5 %)	1_FIT_001_PV (5 %)	1_FIT_001_PV (7 %)	1_FIT_001_PV (1 %)
	2_P_004_SPEED (2 %)	2_P_004_SPEED (2 %)	2_P_004_SPEED (2 %)	2_P_004_SPEED (5 %)	2_FIC_501_SP (1 %)
	2_MV_006_ST (2 %)	2_MV_006_ST (2 %)	2_MV_006_ST (2 %)	2_MV_006_ST (2 %)	2_FIT_002_PV (1 %)
	2_FIC_401_SP (1 %)	2_MV_301_ST (1 %)	2_MV_301_ST (1 %)	2_MV_301_ST (1 %)	2_FIC_301_PV (1 %)
12	1_FIT_001_PV (32 %)	1_FIT_001_PV (34 %)	2_P_004_SPEED (40 %)	2_P_004_SPEED (40 %)	1_P_001_ST (75 %)
	2_P_004_SPEED (21 %)	2_P_004_SPEED (22 %)	1_FIT_001_PV (27 %)	1_FIT_001_PV (17 %)	1_P_003_ST (15 %)
	2_PIC_003_CO (19 %)	2_PIC_003_CO (20 %)	2_PIC_003_CO (11 %)	2_PIC_003_CO (11 %)	2_FQ_501_PV (4 %)
	2_FIC_501_SP (12 %)	2_FIC_501_SP (13 %)	2_MCV_401_CO (10 %)	2_MCV_401_CO (9 %)	2_FIC_501_CO (3 %)
	2_FIC_301_CO (8 %)	2_FIC_301_CO (9 %)	2_FQ_401_PV (8 %)	2_FQ_401_PV (8 %)	1_P_005_ST (3 %)
13	1_FIT_001_PV (35 %)	1_FIT_001_PV (35 %)	1_FIT_001_PV (39 %)	1_FIT_001_PV (80 %)	1_FIT_001_PV (91 %)
	2_FIC_501_SP (30 %)	2_FIC_501_SP (30 %)	2_FIC_501_SP (34 %)	2_FIC_501_SP (7 %)	2_FIC_601_SP (4 %)
	2_FIT_001_PV (17 %)	2_FIT_001_PV (17 %)	2_FIT_001_PV (8 %)	2A_AIT_004_PV (4 %)	2_FIC_501_SP (2 %)
	2_FIC_601_SP (5 %)	2_FIC_601_SP (5 %)	2_FIC_601_SP (7 %)	2_FIT_001_PV (3 %)	2_FIT_001_PV (1 %)
	2A_AIT_004_PV (4 %)	2A_AIT_004_PV (3 %)	2A_AIT_004_PV (3 %)	2_FIC_601_SP (3 %)	1_AIT_001_PV (1 %)

Tabla III

TOP-5 DE GRUPOS DE CARACTERÍSTICAS MÁS RELEVANTES POR ATAQUE, COMPARANDO LA EXPLICACIÓN BASE (SHATS) CON DISTINTAS CONFIGURACIONES DE REUTILIZACIÓN EXPLICATIVA (IG-SHATS) BAJO DIFERENTES RESTRICCIONES SOBRE EL TIEMPO DE RESPUESTA.

Sesión de pósters 2

Arquitectura Adaptativa de IDS Federado para la Mitigación de Amenazas mediante Aprendizaje Semisupervisado en redes IoT/IIoT altamente heterogéneas

Luis Miguel García-Sáez^{*1}, Sergio Ruiz-Villafranca^{†2}, José Roldán-Gómez^{†3},
Javier Carrillo-Mondéjar^{†3}, José Luis Martínez^{†1}

¹Universidad de Castilla-La Mancha, C/ Investigación 2, 02071 Albacete, España

²Universidad Politécnica de Madrid, C/ Alan Turing s/n, 28031 Madrid, España

³Universidad de Zaragoza, C/ María de Luna 3, 50018 Zaragoza, España

E-mail: {luism.garcia, joseluis.martinez}@uclm.es, sergio.rvillafranca@upm.es, {jroldan, jcarrillo}@unizar.es

^{*}Corresponding author [†]Contributing author

Resumen—El Internet de las Cosas (IoT) y el Internet Industrial de las Cosas (IIoT) modernos han evolucionado hacia entornos diversos y dinámicos. En estos entornos, miles de millones de dispositivos operan bajo condiciones heterogéneas y están expuestos a una amplia variedad de amenazas cibernéticas. Esta diversidad desafía a los Sistemas de Detección de Intrusiones (IDS) y a los enfoques de Aprendizaje Federado (FL) convencionales, que generalmente dependen de un único modelo global y ofrecen una personalización limitada. En consecuencia, su rendimiento se degrada cuando los dispositivos experimentan patrones de tráfico o comportamientos de ataque inusuales. Este trabajo presenta una arquitectura adaptativa de FL-IDS semisupervisada que integra clustering no supervisado con aprendizaje supervisado local para mejorar la coordinación y la resiliencia en redes IoT/IIoT distribuidas. Cada nodo en el borde genera firmas estadísticas compactas a partir de los datos locales y participa en un agrupamiento basado en densidad, formando clústeres dinámicos de clientes con comportamientos similares. Esta organización adaptativa permite el entrenamiento colaborativo dentro de grupos homogéneos, preservando la privacidad con una sobrecarga de comunicación mínima. La propuesta ha sido evaluada en dos conjuntos de datos representativos de detección de intrusiones en IoT/IIoT, X-IIoTID y RT-IoT22, utilizando clasificadores supervisados ligeros y ampliamente adoptados. Los resultados muestran mejoras consistentes frente a las estrategias FedAvg y FedProx, manteniendo valores de F1-score superiores a 0.95 bajo condiciones de muy alta heterogeneidad (non-IID). Esto confirma la eficiencia y escalabilidad de la agregación, con un impacto mínimo en el tiempo de ejecución y hasta un 50–90 % de convergencia más rápida.

Index Terms—Internet of Things, Federated Learning, Intrusion Detection, Cybersecurity, Edge Intelligence.

Tipo de contribución: *Investigación original*

I. INTRODUCCIÓN

Los entornos que integran el Internet de las Cosas (IoT) y el Internet Industrial de las Cosas (IIoT) despliegan sistemas de detección de intrusiones (IDS) sobre dispositivos y nodos edge con perfiles de tráfico, superficies de ataque y condiciones operativas muy diferentes. En este contexto,

los datos locales dejan de ser independientes e idénticamente distribuidos y pasan a exhibir heterogeneidad marcada entre clientes, lo que complica tanto el aprendizaje colaborativo como la detección fiable de amenazas raras o específicas de contexto [1], [2]. Esta condición de datos no independientes e idénticamente distribuidos (non-IID) no es marginal. En escenarios industriales y de sensorización distribuida, distintos dominios de red observan mezclas de clases, patrones de telemetría y frecuencias de ataque muy desbalanceadas. En consecuencia, uno de los retos principales en sistemas de aprendizaje federado (FL) aplicados a IDS, no es sólo preservar la privacidad, sino aprender bajo condiciones non-IID severas sin diluir patrones locales relevantes ni perjudicar a los clientes menos representados.

Además, en despliegues reales la heterogeneidad no procede únicamente de la distribución estadística de las muestras, sino también de diferencias de escala temporal, cambios de modo operativo y desalineamientos entre sensores, gateways y dispositivos industriales. Esta combinación provoca que dos clientes observen tráficos benignos y maliciosos con estructuras muy distintas aun cuando pertenezcan al mismo dominio funcional. Por ello, un IDS federado eficaz debe ser capaz de explotar conocimiento compartido sin forzar una homogeneización artificial del comportamiento local, especialmente cuando la detección temprana depende de patrones sutiles y poco frecuentes.

Los enfoques globales clásicos, como FedAvg y FedProx, ofrecen coordinación simple y estable en escenarios moderadamente heterogéneos, pero su estrategia de agregación tiende a promediar actualizaciones incompatibles y a perjudicar la personalización cuando los clientes se apartan del comportamiento dominante [3], [4]. En FL-IDS para IoT/IIoT, este problema se traduce en menor sensibilidad frente a ataques minoritarios, peores tasas de detección en clientes extremos y una convergencia menos uniforme a medida que crece

la disparidad distribucional. Dicho de otro modo, un único modelo global puede resultar adecuado en promedio y, sin embargo, fallar precisamente en aquellos nodos cuya casuística local exige una respuesta más especializada.

Frente a ello, trabajos cercanos han explorado IDS federados para IoT, FL con clustering o esquemas jerárquicos para heterogeneidad, pero todavía persisten limitaciones en personalización efectiva, validación específica sobre tráfico IoT/IoT y eficiencia bajo non-IID fuerte [2], [5], [6], [7], [8]. Para abordar este hueco, proponemos una arquitectura modular de FL-IDS semisupervisada en la que los clientes se agrupan dinámicamente según firmas estadísticas derivadas de sus datos locales y del estado del modelo. Las contribuciones principales son: i) una coordinación federada adaptativa basada en familias de clientes; ii) un pipeline ligero que combina entrenamiento supervisado, microclustering local y agrupamiento global por densidad; y iii) una validación sobre los datasets X-IIoTID y RT-IoT22 con modelos de regresión logística (LR), máquinas de soporte vectorial (SVM) y perceptrón multicapa (MLP). En la configuración principal, el enfoque propuesto alcanza en ronda 10 valores de F1-score de 0.9700 y 0.9848 en RT-IoT22 para LR y SVM, respectivamente, y de 0.9392, 0.9573 y 0.9507 en X-IIoTID para LR, SVM y MLP, superando de forma consistente a FedAvg y FedProx y alcanzando rendimiento equivalente en menos rondas. Estos resultados apuntan a que una coordinación basada en afinidad distribucional ofrece un compromiso más robusto entre especialización local, estabilidad de entrenamiento y coste operativo.

II. DISEÑO DE LA ARQUITECTURA

La arquitectura sigue un diseño Edge-Federated con múltiples nodos en el borde coordinados por un servidor central. Cada cliente agrega y preprocesa tráfico y telemetría de su entorno IoT/IoT, entrena un clasificador supervisado con sus datos etiquetados y realiza una etapa de clustering local. Tras esto, envía al coordinador únicamente actualizaciones del modelo y una firma estadística compacta con la información clave del clustering local. El servidor no accede a los datos en bruto; su papel es orquestar las rondas, descubrir afinidades entre clientes y redistribuir modelos especializados por grupos. Con ello, el servidor realiza una etapa de clustering global basada en densidad y la colaboración deja de realizarse sobre un único modelo global y pasa a adaptarse a subpoblaciones con comportamiento de red parecido. Esta separación entre entrenamiento local y coordinación global permite conservar la privacidad y, al mismo tiempo, introducir un grado de personalización que resulta especialmente relevante cuando los clientes operan bajo amenazas o regímenes de red muy distintos.

El pipeline se resume en dos etapas por ronda. Primero, cada cliente entrena localmente, extrae una firma estadística mediante MiniBatch K-Means sobre representaciones locales y envía dicha firma junto con la actualización del modelo [9]. El número de microclústeres se ajusta dinámicamente según la compactación intra-cluster, evitando sobresegmentación. La

firma resultante actúa como un descriptor ligero del comportamiento local, ya que resume tanto la estructura de los datos como la respuesta del modelo entrenado sobre ellos. Segundo, el servidor transforma las firmas recibidas, agrupa a los clientes con HDBSCAN [10] y agrega los modelos por familias mediante pesos proporcionales al volumen de datos local. De este modo, cada cliente recibe en la siguiente ronda un modelo experto alineado con su contexto operativo, lo que reduce interferencias entre distribuciones muy distintas y favorece una transferencia de conocimiento más positiva. Además, la reasignación por familias se mantiene estable entre rondas, evitando cambios espurios en la colaboración y favoreciendo una convergencia más consistente.

Desde un punto de vista funcional, esta estrategia introduce una forma de personalización estructurada: el sistema no entrena un modelo distinto por cliente, pero tampoco impone una agregación indiscriminada sobre toda la federación. En su lugar, define dominios intermedios de colaboración en los que el intercambio de conocimiento se produce entre clientes suficientemente parecidos. Esto es especialmente ventajoso en IoT/IoT, donde la diversidad de escenarios puede hacer que la transferencia entre nodos no relacionados sea incluso contraproducente.

III. CONFIGURACIÓN EXPERIMENTAL

La evaluación se realizó con los conjuntos de datos X-IIoTID y RT-IoT22 [11], [12], aplicando un preprocesado homogéneo basado en eliminación de campos redundantes, codificación binaria de variables categóricas y normalización en $[0, 1]$. Para emular heterogeneidad entre clientes, las particiones se generaron mediante Dirichlet con $\alpha \in \{10, 1, 0, 1\}$ [13]. El entorno federado incluyó 10 clientes, 10 rondas de comunicación, 3 épocas locales por ronda, batch size de 128 y learning rate de 0.001. Se consideraron LR, SVM y MLP como clasificadores locales, y FedAvg y FedProx como baselines. En la configuración principal se usó $\alpha = 0,1$ para LR y SVM, y $\alpha = 0,3$ para MLP, con $\mu = 0,1$ para FedProx. Las métricas reportadas fueron accuracy, F1-score y runtime total.

IV. RESULTADOS

La Tabla I resume los resultados finales de la ronda 10 en la configuración principal. El comportamiento más robusto aparece en SVM y MLP: en RT-IoT22, la propuesta alcanza 0.9848 de F1 con SVM y 0.9764 con MLP, mientras que en X-IIoTID obtiene 0.9573 y 0.9507, respectivamente. También LR mejora claramente frente a las referencias en RT-IoT22, aunque en X-IIoTID la ganancia es más moderada. En conjunto, los resultados confirman que la agregación por familias preserva mejor la especialización local que los promedios globales de FedAvg y FedProx. El efecto es particularmente visible en los casos más exigentes, donde las estrategias convencionales sufren más al mezclar actualizaciones procedentes de clientes con distribuciones muy dispares.

A nivel comparativo, RT-IoT22 muestra una ventaja muy marcada para la propuesta en los tres clasificadores, lo que sugiere que el mecanismo de agrupamiento resulta especialmente

Tabla I
RESULTADOS FINALES EN RONDA 10 PARA LA CONFIGURACIÓN PRINCIPAL ($\alpha = 0,1$ EN LR/SVM Y $\alpha = 0,3$ EN MLP)

Dataset	Modelo	Nuestra propuesta		FedAvg		FedProx	
		Acc.	F1	Acc.	F1	Acc.	F1
RT-IoT22	LR	0.9760	0.9700	0.9026	0.8927	0.8317	0.8075
	SVM	0.9885	0.9848	0.9513	0.9524	0.8621	0.8764
	MLP	0.9748	0.9764	0.8439	0.7699	0.9335	0.8708
X-IIoTID	LR	0.9294	0.9392	0.8518	0.8734	0.8833	0.8895
	SVM	0.9578	0.9573	0.8999	0.9194	0.9041	0.9088
	MLP	0.9423	0.9507	0.5413	0.4520	0.5554	0.4618

Tabla II
COMPARATIVA DE ACCURACY Y F1-SCORE PARA DIFERENTES VALORES DE α

Dataset	Estrategia	$\alpha = 10$		$\alpha = 1$		$\alpha = 0,1$	
		Acc.	F1	Acc.	F1	Acc.	F1
RT-IoT22	Nuestra propuesta	0.9901	0.9899	0.9914	0.9909	0.9649	0.9646
	FedAvg	0.9933	0.9771	0.9831	0.9609	0.7549	0.6819
	FedProx	0.9906	0.9874	0.9755	0.9697	0.8781	0.8274
X-IIoTID	Nuestra propuesta	0.9794	0.9790	0.9770	0.9779	0.9407	0.9396
	FedAvg	0.9765	0.9759	0.9720	0.9742	0.8181	0.8514
	FedProx	0.9795	0.9791	0.9754	0.9762	0.7822	0.7486

útil cuando la variabilidad entre nodos afecta de forma acusada al espacio de decisión del modelo. En X-IIoTID, aunque la diferencia con LR es menor, SVM y MLP siguen mostrando mejoras claras frente a ambos baselines, especialmente en F1-score. Esto es relevante porque, en detección de intrusiones multiclase, el F1-score ofrece una medida más informativa que el accuracy cuando existen clases minoritarias o desequilibrios entre tráfico benigno y malicioso.

Otra observación importante es que la mejora no parece depender de un único clasificador. Aunque la magnitud del beneficio varía entre LR, SVM y MLP, la tendencia general se mantiene, lo que refuerza la idea de que la aportación principal del método reside en la estrategia de coordinación federada más que en una arquitectura concreta de aprendizaje supervisado. Esta propiedad resulta valiosa para escenarios edge, donde la capacidad de cómputo disponible puede obligar a alternar entre modelos ligeros y modelos algo más expresivos según el nodo o la aplicación.

Los resultados también sugieren que el enfoque propuesto no sólo incrementa la media de rendimiento, sino que suaviza el efecto de clientes desfavorables o distribuciones extremas sobre la agregación conjunta. En la práctica, esto implica una federación menos dominada por los nodos mayoritarios y una colaboración más equilibrada entre contextos operativos distintos. Para un IDS distribuido, esta propiedad es especialmente relevante, ya que una mejora modesta en promedio puede ocultar fallos severos en subpoblaciones concretas; en cambio, la agrupación por afinidad distribucional tiende a reducir este riesgo.

La Tabla II muestra el impacto de diferentes niveles de heterogeneidad sobre las diferentes propuestas. Cuando α disminuye, FedAvg y FedProx degradan con más intensidad, mientras que nuestro enfoque conserva F1-score de 0.9646 en RT-IoT22 y 0.9396 en X-IIoTID para $\alpha = 0,1$. Por tanto, el

beneficio del agrupamiento adaptativo no se limita al rendimiento final, sino también a una degradación más controlada bajo non-IID severo.

En términos de eficiencia, la sobrecarga media de runtime introducida por el agrupamiento se mantiene alrededor del 7%; en X-IIoTID las desviaciones permanecen dentro de $\pm 5\%$, mientras que en RT-IoT22 se sitúan aproximadamente entre 10% y 12% debido a la mayor complejidad del agrupamiento. Aun así, la arquitectura converge antes y compensa ese coste adicional. La Tabla III muestra que el rendimiento final de referencia suele alcanzarse en la ronda 1 o 4, con ahorros de tiempo estimados que llegan hasta el 90.2% en X-IIoTID y el 89.0% en RT-IoT22.

V. CONCLUSIONES

La arquitectura federada semisupervisada propuesta demuestra que, en FL-IDS para IoT/IIoT, la agregación guiada por familias de clientes es más adecuada que el uso de un único modelo global cuando los datos son fuertemente non-IID. El enfoque mejora de forma consistente a FedAvg y FedProx en accuracy y F1-score, mantiene una degradación más suave conforme aumenta la heterogeneidad y alcanza rendimientos equivalentes en menos rondas, con una sobrecarga computacional reducida. En consecuencia, la propuesta constituye una alternativa práctica y escalable para IDS distribuidos sobre nodos edge heterogéneos. Como trabajo futuro, se plantea extender el enfoque hacia esquemas descentralizados y su validación en entornos edge reales [14].

AGRADECIMIENTOS

Este trabajo ha sido financiado por la Universidad de Castilla-La Mancha mediante el contrato predoctoral 2024-UNIVERS-12844, cofinanciado por el Fondo Social Europeo

Tabla III

CONVERGENCIA A OBJETIVO Y AHORRO DE TIEMPO ESTIMADO FRENTE A FEDAVG Y FEDPROX. R^* INDICA LA PRIMERA RONDA EN LA QUE NUESTRA PROPUESTA ALCANZA O SUPERA EL RENDIMIENTO DE LA RONDA 10 DE LA REFERENCIA

Dataset	Modelo	vs. FedAvg		vs. FedProx	
		R^* / Acc.	R^* / F1	R^* / Acc.	R^* / F1
RT-IoT22	LR	1 / 88.8 %	1 / 88.8 %	1 / 89.0 %	1 / 89.0 %
	SVM	4 / 54.9 %	4 / 54.9 %	1 / 88.8 %	1 / 88.8 %
	MLP	4 / 56.3 %	4 / 56.3 %	10 / -11.2 %	4 / 55.5 %
X-IIoTID	LR	1 / 90.1 %	4 / 60.4 %	4 / 59.4 %	4 / 59.4 %
	SVM	4 / 60.1 %	4 / 60.1 %	4 / 59.1 %	4 / 59.1 %
	MLP	1 / 89.5 %	1 / 89.5 %	1 / 90.2 %	1 / 90.2 %

Plus (FSE+). Asimismo, ha contado con el apoyo del proyecto de I+D PID2024-158682OB-C32, financiado por MICIU/AEI/10.13039/501100011033 y cofinanciado por el Fondo Europeo de Desarrollo Regional (FEDER/UE). Además, ha recibido apoyo adicional de los proyectos PID2022-142332OA-I00 y PID2023-151467OA-I00, financiados por MICIU y por la Unión Europea a través del Plan de Recuperación, Transformación y Resiliencia (NextGenerationEU/PRTR).

REFERENCIAS

- [1] M. Ye, X. Fang, B. Du, P. C. Yuen, and D. Tao, "Heterogeneous Federated Learning: State-of-the-art and Research Challenges," *ACM Comput. Surv.*, vol. 56, no. 3, pp. 79:1–79:44, Oct. 2023.
- [2] R. Lazzarini, H. Tianfield, and V. Charissis, "Federated Learning for IoT Intrusion Detection," *AI*, vol. 4, no. 3, pp. 509–530, Sep. 2023.
- [3] B. McMahan, E. Moore, D. Ramage, S. Hampson, and B. A. y. Arcas, "Communication-Efficient Learning of Deep Networks from Decentralized Data," in *Proceedings of the 20th International Conference on Artificial Intelligence and Statistics*. PMLR, Apr. 2017, pp. 1273–1282, iSSN: 2640-3498.
- [4] T. Li, A. K. Sahu, M. Zaheer, M. Sanjabi, A. Talwalkar, and V. Smith, "Federated Optimization in Heterogeneous Networks," in *Proceedings of Machine Learning and Systems*, vol. 2, Mar. 2020, pp. 429–450.
- [5] E. S. Lubana, C. I. Tang, F. Kawsar, R. P. Dick, and A. Mathur, "Orchestra: Unsupervised Federated Learning via Globally Consistent Clustering," Jun. 2022, arXiv:2205.11506 [cs].
- [6] G. d. C. Bertoli, L. A. P. Junior, A. L. d. Santos, and O. Saotome, "Generalizing intrusion detection for heterogeneous networks: A stacked-unsupervised federated learning approach," *Computers & Security*, vol. 127, p. 103106, Apr. 2023, arXiv:2209.00721 [cs].
- [7] C. Qiu, Z. Wu, H. Wang, Q. Yang, Y. Wang, and C. Su, "Hierarchical Aggregation for Federated Learning in Heterogeneous IoT Scenarios: Enhancing Privacy and Communication Efficiency," *Future Internet*, vol. 17, no. 1, p. 18, Jan. 2025.
- [8] H. Zhang, Z. Li, S. Xi, X. Zhao, J. Liu, and P. Zhang, "Heterogeneity-aware device selection for clustered federated learning in IoT," *Peer-to-Peer Networking and Applications*, vol. 18, no. 1, p. 29, Dec. 2024.
- [9] D. Sculley, "Web-scale k-means clustering," in *Proceedings of the 19th international conference on World wide web*, ser. WWW '10. New York, NY, USA: Association for Computing Machinery, 2010, pp. 1177–1178.
- [10] R. J. G. B. Campello, D. Moulavi, and J. Sander, "Density-Based Clustering Based on Hierarchical Density Estimates," in *Advances in Knowledge Discovery and Data Mining*, J. Pei, V. S. Tseng, L. Cao, H. Motoda, and G. Xu, Eds. Berlin, Heidelberg: Springer, 2013, pp. 160–172.
- [11] M. Al-Hawawreh, E. Sitnikova, and N. Aboutorab, "X-IIoTID: A Connectivity-Agnostic and Device-Agnostic Intrusion Data Set for Industrial Internet of Things," *IEEE Internet of Things Journal*, vol. 9, no. 5, pp. 3962–3977, Mar. 2022.
- [12] B. S. Sharmila and R. Nagapadma, "Quantized autoencoder (QAE) intrusion detection system for anomaly detection in resource-constrained IoT devices using RT-IoT2022 dataset," *Cybersecurity*, vol. 6, no. 1, p. 41, Sep. 2023.
- [13] N. Balakrishnan and V. B. Nevzorov, "Dirichlet Distribution," in *A Primer on Statistical Distributions*. John Wiley & Sons, Ltd, 2003, pp. 269–276.
- [14] L. Yuan, Z. Wang, L. Sun, P. S. Yu, and C. G. Brinton, "Decentralized Federated Learning: A Survey and Perspective," *IEEE Internet of Things Journal*, vol. 11, no. 21, pp. 34 617–34 638, Nov. 2024.

Simulating cyber influence operations in synthetic online social networks

David Montoro Aguilera*, Alejandro Buitrago López*, Javier Pastor-Galindo*, José A. Ruipérez-Valiente*

*Department of Information and Communications Engineering, University of Murcia, 30100 Murcia, Spain
{d.montoroaguilera, alejandro.buitragol, javierpg, jruiperez}@um.es

Abstract—Influence operations are an established feature of online information environments, and recent large language models may reduce the cost of producing persuasive content at scale. We present a controlled testbed for studying LLM-assisted influence operations in synthetic online social networks. Focusing on a *Narrative Release* campaign, we examine how the proportion of red-controlled accounts affects campaign reach and belief change. Results show a clear density-dependent pattern: low-density campaigns mainly increase visibility, whereas higher-density campaigns achieve broad reach and measurable belief change.

Index Terms—Cyber defense, Artificial Intelligence, Influence Operations, Information Warfare

Type of contribution: *Research in development*

I. INTRODUCTION

Online social networks (OSNs) are a primary venue for news discovery and large-scale information diffusion, shaping what users see and how narratives propagate through social connections [1]. This also makes them an operational attack surface: adversaries can seed content, coordinate engagement, and use automation to exploit platform amplification at scale. [2]. We refer to these coordinated campaigns as influence operations (IOs), i.e., efforts to steer attitudes or behavior in support of an adversary’s objectives [3].

IOs increasingly appear in the threat landscape as part of hybrid operations, where informational effects are orchestrated alongside technical capabilities, shared infrastructure, and repeatable tactics, techniques, and procedures (TTPs) [4].

Recent advances in large language models (LLMs) further expand these operational capabilities by reducing the cost of producing persuasive, audience-tailored messages and enabling rapid narrative variation [5]. Consequently, the effects of such campaigns can extend beyond the platform into public discourse and, in some cases, into institutional trust and decision-making across domains ranging from public health to geopolitics [6].

Despite a growing body of empirical work on the role of IOs in shaping information diffusion and public outcomes [7], studying adversarial campaigns remains methodologically constrained [8]. Analyses of real platforms typically rely on partial observability, platform-specific measurement artifacts, and limited access to ranking and recommendation mechanisms, which complicates attribution, counterfactual analysis, and generalization [9]. In this context, simulation provides a complementary testbed for controlled, repeatable experiments on how adversarial interventions affect diffusion and audience beliefs [10], [11]. However, recent simulation work often prioritizes scale and behavioral realism or reproduces case-specific attacker dynamics, rather than isolating the impact of

a well-defined influence mechanism under controlled attacker capabilities [10], [12].

In this work, we study LLM-assisted IOs through controlled, repeatable experiments in synthetic social networks. We design and implement a DISARM-aligned *Narrative Release* workflow, which operationalizes proactive narrative injection through strategic seeding by red-controlled accounts. Using an agent-based OSN simulator, we evaluate how varying the operational footprint of the campaign affects two complementary outcomes: IO reach, defined as exposure to red-authored content, and belief change in the target audience. In doing so, we provide a controlled framework to examine when narrative release increases visibility only and when it produces measurable persuasion effects.

II. RELATED WORK

Prior research has characterized information diffusion in OSNs and documented how influence operations (IOs) exploit coordinated behavior, automation, and amplification mechanisms [13]. However, evidence from real platforms is often constrained by partial observability, opaque ranking systems, and platform-specific measurement choices [14]. These limitations motivate simulation-based approaches, which provide controlled and repeatable settings for studying adversarial influence dynamics.

Recent agent-based and LLM-driven simulations pursue two main goals: reproducing aggregate social phenomena at scale and modeling richer individual behavior. OASIS [10] shows that large-scale simulations can reproduce aggregate phenomena in X- and Reddit-like settings, but its evaluation emphasizes plausibility at scale rather than isolating the effect of a specific adversarial intervention. Likewise, Y-Social [15] adopts a digital-twin perspective in which LLMs drive richly profiled agents, yet its focus on realism leaves open how to perform systematic, security-oriented evaluations of concrete influence mechanisms.

Work that explicitly targets IO emulation begins to address this gap, although often with limited generality. Beskow and Carley [12] instantiate canonical maneuvers such as backing key influencers and bridging communities, linking tactics to network structure. More recent LLM-based sandboxes [16] move closer to modeling adversarial interaction, but their evaluations often depend on campaign-specific settings or content-level assumptions that make it difficult to isolate the effect of narrative injection itself.

Taken together, prior work motivates the need for a repeatable, security-oriented experimental protocol that isolates the effect of proactive narrative injection from baseline diffusion

dynamics. Our work addresses this gap by embedding LLM-assisted offensive agents in a synthetic OSN and evaluating a DISARM-aligned *Narrative Release* workflow in terms of reach and belief change.

III. FRAMEWORK FOR AGENT-BASED SIMULATION OF SOCIAL NETWORKS AND INFLUENCE OPERATIONS

To support controlled and repeatable experiments, we build on an agent-based OSN simulation framework that separates network generation, agent behavior, and diffusion mechanisms. Prior work describes the base simulator and its calibration to real-network structural signatures [11]. In this paper, we extend that framework with an explicit adversarial layer, the Red Module, which operationalizes a *Narrative Release* campaign through a subset of red-controlled accounts.




Fig. 1: Overview of the framework for simulating OSN activity and adversarial narrative release [11].

Figure 1 summarizes the framework. The OSN Generator first instantiates a directed microblogging-style follower graph with attribute-driven community structure. Nodes are assigned compact semantic profiles, and links are formed through homophily-guided selection, triadic closure, and sparse long-range ties. The resulting topology is calibrated to reproduce structural signatures observed in real networks, providing a controlled yet realistic diffusion environment [17].

Once the graph is instantiated, the OSN Simulation Manager advances the simulation through the OSN Simulator. Agent behavior is governed by interpretable, rule-based decision models, while LLMs are used only for linguistic realization through the Generative Module. This design preserves reproducibility and causal interpretability at the behavioral level.

Adversarial activity is introduced through the Red Module, which overlays the same simulator used for organic interaction without altering platform mechanics such as network structure, feed dynamics, or available actions. Instead, it constrains how selected accounts generate and prioritize content, thereby isolating the effect of the adversarial intervention from environmental confounds.

In the present study, the Red Module operationalizes a *Narrative Release* workflow. A campaign specification defines the topic, target narrative, start time, duration, and operational

density of red-controlled accounts. At runtime, the module maps these parameters to an execution policy that schedules when red agents act and how their content is conditioned on the injected narrative. Red agents still operate through the simulator’s native primitives, but their posts and interactions are guided by narrative-conditioned prompt templates, enabling coordinated strategic seeding.

Finally, the framework exposes simulation events—including users, connections, interactions, and timestamps—to external analysis layers, supporting the evaluation of campaign effects through IO reach and belief change.

IV. METHODOLOGY

The Red Module operationalizes adversarial behavior as a controllable intervention layer within the simulator. In our setting, influence operations are modeled as explicit tactics, techniques, and procedures (TTPs), rather than as generic malicious agents, enabling repeatable execution and controlled comparison across attacker capabilities.

To represent these TTPs, we adopt the **DISARM Framework** as the main modeling reference. DISARM organizes influence operations as a kill-chain of adversarial actions and provides a modular, technique-level structure well suited to controlled simulation [5].

In this paper, we instantiate a single DISARM-aligned workflow: **Narrative Release**. This workflow captures the proactive injection of a new framing into an ongoing discussion. It combines narrative creation and division techniques (*T0079 Divide*, *T0082 Develop New Narratives*) with AI-assisted text generation (*T0085.001 Develop AI-Generated Text*) and dissemination through standard platform actions (*T0115 Post Content*, *T0116 Comment/Reply*). Operationally, red-controlled accounts seed the selected narrative and sustain its visibility through repeated posting and interaction. The workflow further assumes offline audience selection and account provisioning (*T0073 Determine Target Audiences*, *T0090 Create Inauthentic Accounts*), implemented as assigning a subset of agents to the red team with realistic cyberpersona profiles.

A. Experimental design

We evaluate how red-agent density modulates IO reach and belief change under a *Narrative Release* campaign. Each simulation instance is defined by a topic discussed by all agents and a target narrative used exclusively by red agents to steer content generation. Topics and narratives are drawn from *EU Disinfo Test* [18], grounding the prompts in empirically documented disinformation themes.

In our experiments, the selected topic is “**Immigration in Europe**”, and the injected narrative is “*Immigrants are a threat to European society, culture and race*”. This narrative is represented in *EU Disinfo Test* [18], while the topic remains highly salient in online public debate [19].

All simulations use the same technical setup to isolate the effect of operational density. We fix the network at 1,000 agents as a practical trade-off between interaction richness and computational cost. The main experimental factor is the proportion of red-controlled accounts, varied across seven levels (0%, 4%, 6%, 8%, 15%, 30%, and 45%). The 0%

condition serves as the no-IO baseline, capturing endogenous opinion drift under organic interaction alone, while the remaining conditions progressively increase the operational footprint of the campaign. For each configuration, we execute five independent runs with different random seeds and report metrics aggregated across runs.

B. Effectiveness metrics

We quantify campaign effectiveness by separating *exposure* from *belief updating*, since visibility alone does not imply persuasion.

Exposure (IO reach). IO reach is the fraction of benign agents exposed to the operation at least once. An agent is counted as reached if the simulator records a *read* event for any message authored by a red-controlled account. Reach therefore reflects content consumption rather than the sheer volume of messages produced.

Belief change (opinion shift). To assess whether exposure translates into attitude change, we elicit per-agent beliefs about the injected narrative. At each assessment checkpoint, an interview-style protocol prompts an LLM to answer *as the agent*, conditioned on the agent’s cyberpersona and accumulated context. Responses to repeated items spanning five dimensions are mapped to a normalized five-dimensional belief vector. Opinion shift is then measured as the Jensen–Shannon divergence (JSD) between pre-exposure and post-exposure belief vectors. JSD lies in $[0, 1]$, where 0 indicates no change and larger values indicate greater belief reconfiguration with respect to the narrative. Beliefs are elicited at quartile checkpoints to capture both the trajectory and magnitude of belief updating over time.

V. RESULTS

We now present the empirical effects of the *Narrative Release* campaign in the simulated social networks. We examine two complementary outcomes as operational density increases: IO reach, which captures exposure to red-authored content, and opinion shift, which captures changes in agents’ beliefs with respect to the injected narrative.

Red agents follow the same action-selection policy as benign agents (Section III) and differ primarily in that their generated content is conditioned on the released narrative. This allows us to isolate the effect of strategic narrative injection without altering the underlying interaction dynamics of the platform.

A. IO reach

Figure 2 reports IO reach, computed over benign agents only (e.g., in the 15% condition, exposure is evaluated over the remaining 85% of the network). Reach exhibits greater run-to-run variability at low operational densities (4–8%), consistent with stochastic differences in early exposure pathways. By contrast, higher densities produce consistently high reach across seeds. In particular, campaigns with 30% red agents exceed 80% reach in all runs, while 45% red-agent campaigns approach full-network exposure.

This pattern suggests that low-density operations depend more strongly on the local placement of red-controlled accounts and the contingent diffusion of their messages, whereas




Fig. 2: Distribution of IO reach across five simulations per red-agent configuration.

higher-density campaigns benefit from repeated exposure opportunities distributed throughout the network. As operational density increases, the number of red-authored messages read by benign agents grows accordingly, leading to broader and more stable exposure.

B. Opinion shift

To assess whether exposure translates into persuasion, we analyze both the direction and the magnitude of belief updating.

The **belief value** summarizes each agent’s stance toward the target narrative as the mean of the five elicited belief dimensions, scaled to $[0, 1]$, where 0 indicates complete disagreement and 1 indicates complete agreement. Figure 3 shows that, in the 0% baseline, mean belief declines over time, indicating endogenous drift away from the injected narrative under organic interaction alone. Low-density interventions (4–8%) largely arrest this decline, stabilizing belief around its initial level. Higher-density campaigns (15–45%) instead produce a clear upward shift, with the 45% condition increasing mean belief from approximately 0.4 to 0.6.




Fig. 3: Mean belief-value evolution toward the injected narrative under different red-agent densities.

While these trajectories indicate the direction of change, Jensen–Shannon divergence (JSD) captures the magnitude of overall opinion shift between prior and posterior belief vectors. Across low-to-moderate densities (4–15%), mean JSD remains close to the baseline range (approximately 0.02–0.03; baseline mean = 0.021), suggesting that modest narrative injection does not consistently produce belief updates beyond endogenous variability. A clearer effect emerges at higher densities: mean JSD increases to 0.044 at 30% and reaches 0.074 at 45%, with dispersion also increasing substantially (from STD = 0.028 in the baseline to STD = 0.095 at 45%).




Fig. 4: Distribution of opinion shift (JSD) across red-agent configurations.

The distributional view in Figure 4 is consistent with this pattern: the 45% configuration shows both the highest central tendency and occasional large shifts. Taken together, these results support a volume-driven mechanism for *Narrative Release*: at low densities, the campaign mainly increases visibility and counteracts baseline drift away from the injected narrative, whereas at higher densities it generates repeated exposure sufficient to induce measurable persuasion.

VI. CONCLUSIONS

This work presents a controlled framework for studying influence operations in synthetic, agent-driven online social networks. We extend an agent-based OSN simulator with a red-team module that operationalizes a DISARM-aligned *Narrative Release* campaign over mixed populations of benign and red-controlled agents. Within this setting, LLMs are used only for linguistic realization, while behavioral control remains interpretable and reproducible across runs.

To assess campaign impact, we jointly examine exposure and belief change. Exposure is captured through IO reach, while belief change is measured by eliciting per-agent belief vectors and comparing prior and posterior states via Jensen–Shannon divergence. This allows us to distinguish broad visibility from actual persuasive effect.

Empirically, the results reveal a clear density-dependent pattern. At low operational densities, *Narrative Release* mainly increases visibility and counteracts baseline drift away from the injected narrative, but does not consistently induce substantial persuasion. At higher densities, however, the campaign achieves broad network reach and produces measurable

belief change. These findings indicate that proactive narrative seeding can shape audience beliefs in controlled synthetic OSNs, but that its effectiveness depends strongly on the campaign’s operational footprint.

ACKNOWLEDGEMENTS

This work has been partially funded by the University of Murcia by FPU contract.

REFERENCES

- [1] S. Vosoughi, D. Roy, and S. Aral, “The spread of true and false news online,” *Science*, vol. 359, no. 6380, pp. 1146–1151, 2018. [Online]. Available: <https://www.science.org/doi/abs/10.1126/science.aap9559>
- [2] J. Pastor-Galindo, P. Nespola, J. A. Ruipérez-Valiente, and D. Camacho, “Influence operations in social networks,” 2025. [Online]. Available: <https://arxiv.org/abs/2502.11827>
- [3] E. V. Larson, R. E. Darilek, D. Gibran, B. Nichiporuk, A. Richardson, L. H. Schwartz, and C. Q. Thurston, *Foundations of Effective Influence Operations: A Framework for Enhancing Army Capabilities*. Santa Monica, CA: RAND Corporation, 2009.
- [4] K.-C. Yang and F. Menczer, “Anatomy of an ai-powered malicious social botnet,” *Journal of Quantitative Description: Digital Media*, vol. 4, 2024. [Online]. Available: <https://journalqd.org/article/view/5848>
- [5] S. Terp and P. Breuer, “Disarm: a framework for analysis of disinformation campaigns,” in *2022 IEEE Conference on Cognitive and Computational Aspects of Situation Management (CogSIMA)*, 2022, pp. 1–8.
- [6] A. B. López, J. Pastor-Galindo, and J. A. Ruipérez-Valiente, “Frameworks, modeling and simulations of misinformation and disinformation: A systematic literature review,” 2024. [Online]. Available: <https://arxiv.org/abs/2406.09343>
- [7] H. Allcott and M. Gentzkow, “Social media and fake news in the 2016 election,” *Journal of Economic Perspectives*, vol. 31, no. 2, p. 211–36, May 2017.
- [8] D. M. J. Lazer, A. Pentland, D. J. Watts, S. Aral, S. Athey, N. Contractor, D. Freelon, S. Gonzalez-Bailon, G. King, H. Margets, A. Nelson, M. J. Salganik, M. Strohmaier, A. Vespignani, and C. Wagner, “Computational social science: Obstacles and opportunities,” *Science*, vol. 369, no. 6507, pp. 1060–1062, 2020.
- [9] A. Guess, J. Nagler, and J. Tucker, “Less than you think: Prevalence and predictors of fake news dissemination on facebook,” *Science Advances*, vol. 5, no. 1, p. eaau4586, 2019.
- [10] Z. Yang, Z. Zhang, Z. Zheng, Y. Jiang, Z. Gan, Z. Wang, Z. Ling, J. Chen, M. Ma, B. Dong, P. Gupta, S. Hu, Z. Yin, G. Li, X. Jia, L. Wang, B. Ghanem, H. Lu, C. Lu, W. Ouyang, Y. Qiao, P. Torr, and J. Shao, “Oasis: Open agent social interaction simulations with one million agents,” 2025.
- [11] A. B. López, A. O. Pastor, D. M. Aguilera, M. F. Tárraga, J. V. Chacón, J. Pastor-Galindo, and J. A. Ruipérez-Valiente, “Agent-based simulation of online social networks and disinformation,” 2025. [Online]. Available: <https://arxiv.org/abs/2512.22082>
- [12] D. M. Beskow and K. M. Carley, “Agent based simulation of bot disinformation maneuvers in twitter,” in *2019 Winter Simulation Conference (WSC)*, 2019, pp. 750–761.
- [13] K. Starbird, “Examining the alternative media ecosystem through the production of alternative narratives of mass shooting events on twitter,” *Proceedings of the International AAAI Conference on Web and Social Media*, vol. 11, no. 1, pp. 230–239, May 2017. [Online]. Available: <https://ojs.aaai.org/index.php/ICWSM/article/view/14878>
- [14] D. Ruths and J. Pfeffer, “Social media for large studies of behavior,” *Science*, vol. 346, no. 6213, pp. 1063–1064, 2014. [Online]. Available: <https://www.science.org/doi/abs/10.1126/science.346.6213.1063>
- [15] G. Rossetti, M. Stella, R. Cazabet, K. Abramski, E. Cau, S. Citraro, A. Failla, R. Improta, V. Morini, and V. Pansanella, “Y social: an llm-powered social media digital twin,” 2024.
- [16] M. Nasim, S. M. Gilani, A. Qasmi, and U. Naseem, “Simulating influence dynamics with llm agents,” 2025.
- [17] A. B. López, J. Pastor-Galindo, and J. A. Ruipérez-Valiente, “Synthetic generation of online social networks through homophily,” 2025. [Online]. Available: <https://arxiv.org/abs/2509.02762>
- [18] W. Sosnowski, A. Modzelewski, K. Skorupska, J. Otterbacher, and A. Wierzbicki, “Eu disinfotest: a benchmark for evaluating language models’ ability to detect disinformation narratives,” *Tech. Rep.* [Online]. Available: <https://github.com/wsosnowski/EUDisinfoTest>
- [19] A. Nasuto and F. Rowe, “Understanding anti-immigration sentiment spreading on twitter,” *PLoS ONE*, vol. 19, 9 2024.

Evaluación de la robustez de algoritmos de Machine Learning frente a ataques de envenenamiento de etiquetas en entornos IoMT

Jordi Doménech, Olga León, Isabel V. Martín-Faus, Josep Pegueroles

Departament d'Enginyeria Telemàtica

Universitat Politècnica de Catalunya

c. Jordi Girona 1-3, 08034, Barcelona, Spain

{jordi.domenech.fons, olga.leon, isabel.martin-faus, josep.pegueroles}@upc.edu

Resumen—Los Sistemas de Detección de Intrusiones (IDS) basados en técnicas de aprendizaje automático (ML) son eficaces en la detección de ataques en el Internet de las Cosas Médicas (IoMT). Existen numerosas propuestas de algoritmos de ML orientadas a mejorar la eficiencia en la detección, al tiempo que se mantienen ligeros y computacionalmente viables para entornos con restricciones de recursos. En este contexto, resulta crítico analizar cómo los ataques adversarios afectan al rendimiento de estos modelos. Entre los ataques adversarios, los de envenenamiento (*poisoning attacks*) se caracterizan por la manipulación deliberada de la fase de entrenamiento, introduciendo muestras maliciosas con el objetivo de degradar las predicciones del algoritmo. En este trabajo se evalúa la robustez de distintos modelos de ML frente a ataques de envenenamiento del tipo *label flipping* y se propone la métrica *RL: Robustness Loss* como un parámetro esencial para diseñar el modelo más adecuado en un IDS generalizable y ligero. Además, mediante experimentos usando el dataset IoMT-TrafficData se ha comprobado cómo el balanceo de clases es una estrategia de preprocesado eficiente para mitigar los efectos de este tipo de ataques, recuperando rendimientos del 99 % en algunos modelos.

Index Terms—Ciberseguridad, IDS, IoMT, Aprendizaje Automático, *Poisoning Attacks*, Robustez

Tipo de contribución: Investigación en desarrollo

I. INTRODUCCIÓN

La creciente digitalización de los sistemas sanitarios mediante el *Internet of Medical Things* (IoMT) ha mejorado sustancialmente la eficiencia clínica, pero al mismo tiempo ha ampliado drásticamente la superficie de exposición a ciberataques [1], [2]. Con el objetivo de reducir los riesgos de ciberseguridad, los Sistemas de Detección de Intrusiones (IDS) basados en aprendizaje automático (ML, *Machine Learning*) se han probado como especialmente útiles para identificar comportamientos maliciosos desconocidos y adaptarse a entornos dinámicos como IoMT, manteniendo además requisitos de ligereza computacional que los hacen viables para dispositivos con recursos limitados [3]. Sin embargo, gran parte de la investigación existente en IDS se ha centrado en maximizar métricas clásicas de rendimiento (*Accuracy*, *F1-Score*, ...) bajo escenarios ideales, asumiendo implícitamente la integridad de los datos utilizados en el entrenamiento [4], [5]. Esta suposición ignora el riesgo que supone el *Adversarial Machine Learning* (AML), en particular los ataques de envenenamiento (*poisoning attacks*), donde un atacante manipula los datos durante la fase de entrenamiento. Mediante

técnicas como la alteración de etiquetas (*label flipping*), un atacante puede inducir errores de clasificación y degradar silenciosamente la detección de anomalías, con consecuencias fatales para la seguridad de los pacientes [6], [7].

Este trabajo presenta una evaluación sistemática de la robustez de distintos algoritmos de aprendizaje automático frente a ataques de envenenamiento de etiquetas en un escenario IoMT realista. Utilizando el dataset IoMT-TrafficData [5], se analizan cuatro modelos ligeros y ampliamente utilizados; *Decision Tree*, *Random Forest*, *XGBoost* y una red neuronal simple *Feedforward Neural Network* y, asimismo, ante diferentes estrategias de *label flipping*. Además, se introduce la métrica de *Robustness Loss* para cuantificar la degradación del rendimiento después del ataque adversario y se estudia el efecto del balanceo del dataset como medida defensiva.

La principal contribución de este trabajo es demostrar que en escenarios IoMT, un alto rendimiento en condiciones normales no garantiza la robustez frente a ataques adversarios. Además, factores como la distribución de clases y las técnicas de preprocesamiento se demuestran que son claves en la robustez del modelo. Por ello, se propone incorporar la robustez como un criterio a tener en cuenta en la selección de modelos para IDS en entornos IoMT.

El resto del artículo se organiza como sigue: la Sección II introduce los conceptos relacionados con técnicas adversarias en ML; la Sección III describe el escenario experimental, el dataset utilizado, los modelos evaluados y los experimentos de envenenamiento; la Sección IV presenta y discute los resultados obtenidos; y finalmente, la Sección V recoge las conclusiones y líneas de trabajo futuro.

II. TÉCNICAS ADVERSARIAS

El estudio de los ataques de *poisoning*, donde se manipulan los datos de entrenamiento para degradar el modelo, ha sido explorado extensamente en entornos generales de IoT e IT. Los autores en [8] evaluaron la robustez de modelos frente a ataques de modificación de etiquetas (*label flipping*) en redes IoT, utilizando tasas de envenenamiento de hasta el 30 %. Sin embargo, su análisis se centró en datasets generales como ToN_IoT y UNSW-NB15, sin abordar las particularidades del tráfico en entornos IoMT. En otro artículo se propuso el marco FortiNIDS para defender infraestructuras de ciudades inteligentes, evaluando técnicas como *Reject on Negative*

Impact (RONI) frente al envenenamiento de etiquetas. No obstante, este estudio utiliza el dataset CICDDoS2019, el cual tampoco refleja las dinámicas del IoMT [9]. Recientemente, la comunidad investigadora ha comenzado a utilizar bases de datos específicas como IoMT-TrafficData para mejorar el realismo de las simulaciones, aunque explícitamente señalan la evaluación de la robustez como un trabajo futuro pendiente [10].

Otros trabajos han explorado la robustez frente a ataques adversarios de evasión o perturbaciones en la fase de inferencia del modelo. Por ejemplo, en [11] se propone un transformador adversarial optimizado utilizando IoMT-TrafficData para detectar intrusiones, centrándose en la extracción de características espacio-temporales y la resiliencia ante ataques que ocurren tras el entrenamiento. Por otro lado, los autores en [12] entrenaron modelos de tipo *Fusion Transformer* utilizando IoMT-TrafficData sometido a ruidos y perturbaciones de entrada, pero sin evaluar ataques directos de envenenamiento por modificación de etiquetas durante la fase de entrenamiento. Finalmente, los autores en [13] investigaron la manipulación de modelos en redes IoMT federadas, pero su estudio no incluyó el dataset IoMT-TrafficData. A pesar de la existencia de estudios sobre ciberseguridad en IoMT, actualmente no existe ningún artículo que evalúe específicamente la robustez de modelos de aprendizaje automático para sistemas IDS frente a ataques de envenenamiento (*poisoning*) utilizando la base de datos IoMT-TrafficData. Este artículo aborda dicha brecha, analizando la robustez de distintos modelos frente a ataques de envenenamiento de etiquetas en entornos específicos de IoMT.

III. METODOLOGÍA Y DISEÑO EXPERIMENTAL

III-A. Dataset y modelos de aprendizaje automático

Para garantizar el realismo de la evaluación en redes médicas, se utiliza el dataset IoMT-TrafficData [5]. Este conjunto contiene tráfico benigno y 8 tipos de ataques capturados de dispositivos médicos y sensores heterogéneos (MQTT, CoAP). Se seleccionaron los atributos basados en flujos (95 características de red), ya que logran un rendimiento superior frente a los basados en paquetes. El preprocesamiento se limitó a la estandarización de etiquetas, codificación One-Hot para variables categóricas y normalización Min-Max al rango para evitar sesgos por la amplitud de las variables. Se empleó una división estratificada de 80 % para entrenamiento/validación (con validación cruzada de 5 iteraciones) y 20 % para prueba.

Para la clasificación, se seleccionaron cuatro algoritmos ampliamente utilizados y optimizados para ser computacionalmente ligeros en entornos IoMT con recursos restringidos: Decision Tree (DT), Random Forest (RF), XGBoost (XGB) y Feedforward Neural Network (FNN) [14].

III-B. Definición del ataque y métrica de robustez (RL)

El modelo de amenaza asume un ataque de envenenamiento de etiquetas (*Label Flipping*) en la fase de entrenamiento, donde el atacante tiene la capacidad de modificar las etiquetas del conjunto de datos de entrenamiento (D_{train}) sin alterar las características (features) de los datos. Matemáticamente, si el conjunto original es $D_{train} = \{(x_i, y_i)\}_{i=1}^n$ (donde x corresponde a la clase, y al número de muestras asociadas a la clase, y n al número de clases del dataset), el ataque genera

un conjunto $D'_{train} = \{(x_i, y'_i)\}_{i=1}^n$ donde para una fracción p (donde $p \in \{0,01, 0,05, 0,10\}$), se cumple que $y'_i \neq y_i$. El objetivo del atacante es inducir un error de clasificación en la fase de *test*, desplazando las fronteras de decisión del modelo.

Para evaluar el impacto, se utilizan métricas estándar (*Accuracy*, *Precision*, *Recall* y *F1-Score*). Adicionalmente, se introduce la métrica de *Robustness Loss* (RL), definida en Ec. (1).

$$RL = \frac{M(0) - M(p)}{M(0)} \times 100, \quad (1)$$

Donde $M(0)$ representa el rendimiento del modelo con el 0 % de envenenamiento y $M(p)$ representa el rendimiento bajo ataque (i.e., 1 %, 5 % o 10 % de envenenamiento). Esta métrica permite normalizar la pérdida de rendimiento independientemente de la precisión inicial del modelo. Un valor de *RL* cercano a cero indica una robustez excepcional, mientras que valores elevados señalan una baja resistencia del modelo frente a ataques de envenenamiento.

III-C. Escenarios experimentales

El objetivo de la fase experimental es cuantificar la degradación del rendimiento de los modelos bajo diferentes niveles de estrés por envenenamiento. Se ha diseñado un marco de trabajo dividido en tres experimentos principales, utilizando tasas de cambio de etiquetas (*label flipping rates*) de 0 % (baseline), 1 %, 5 % y 10 %.

- Exp. 1 (Ataque aleatorio - Random Label Flipping): Cambio de etiquetas siguiendo una distribución uniforme. Dado el alto desbalance intrínseco del dataset, este ataque modifica mayoritariamente instancias de clases benignas o mayoritarias, permitiendo evaluar si el ruido se diluye sin afectar severamente al modelo.
- Exp. 2 (Ataque con preservación de distribución - Distribution-Preserving): Un ataque más sofisticado donde la cantidad total de instancias por clase se mantiene constante antes y después del envenenamiento. Esto evade detecciones simples basadas en histogramas y fuerza al modelo a confundir los límites de decisión al aprender características de una clase bajo la etiqueta de otra.
- Exp. 3 (Defensa mediante balanceo): Se propone una estrategia de endurecimiento (*hardening*) aplicando un balanceo híbrido al dataset antes de sufrir el envenenamiento. Se combinó submuestreo aleatorio (RUS) en las clases mayoritarias y sobremuestreo sintético (SMOTE) en los ataques minoritarios. La hipótesis es que un espacio de clases equilibrado genera vectores de soporte más robustos, evitando que el ruido colapse el rendimiento general, evaluándose incluso bajo tasas extremas de hasta el 50 % de envenenamiento.

IV. RESULTADOS Y DISCUSIÓN

Los resultados presentados corresponden a la media de una validación cruzada de 5 iteraciones (*5-fold cross-validation*). Para evaluar el impacto real de los ataques, se comparó el rendimiento base (0 % *label flipping rate*) frente a distintas tasas de alteración de etiquetas (*label flipping*), destacando la eficacia de la métrica propuesta *Robustness Loss* (RL) para cuantificar la caída de rendimiento de forma normalizada.

IV-A. Experimento 1: Envenenamiento aleatorio (Random Label Flipping)

En el escenario de ataque puramente aleatorio, los modelos exhiben una resiliencia aparente excepcional. Incluso con un 10 % de datos envenenados, la degradación es marginal; por ejemplo, el modelo XGBoost (XGB) muestra una pérdida de robustez (RL) en el F1-Score de apenas 0.06 %.

Sin embargo, este fenómeno es un subproducto del elevado desbalance intrínseco del dataset IoMT-TrafficData. Dado que el ruido se introduce siguiendo una distribución uniforme, afecta estadísticamente de forma masiva a las clases mayoritarias (tráfico benigno y CAM Table Overflow). Como consecuencia, este ruido se diluye sin alterar significativamente las fronteras de decisión de los ataques minoritarios, generando una falsa sensación de seguridad en el sistema.

IV-B. Experimento 2: Envenenamiento con Preservación de Distribución (Distribution-Preserving)

El ataque que mantiene constante la proporción de instancias por clase antes y después del envenenamiento (distribution-preserving) inyecta un ruido semántico mucho más difícil de filtrar, resultando ser el escenario más devastador. Al forzar al modelo a aprender características de una clase bajo la etiqueta de otra, se confunden activamente los límites de decisión y la degradación es masiva.

Tal y como se observa en la Tabla I, el algoritmo Decision Tree (DT) demuestra ser el más vulnerable, sufriendo una degradación (RL) del 54.52 % en la métrica Recall. Por su parte, aunque XGB y la Feedforward Neural Network (FNN) resultan ser más solventes, sufren caídas severas cercanas al 23 % en su F1-Score. En la práctica, las matrices de confusión evidencian que los modelos colapsan y pierden por completo la capacidad de distinguir amenazas minoritarias pero críticas como ARP Spoofing, MQTT Malaria, Slow Loris y Slow Read. En un ecosistema médico IoMT, esta ceguera del detector podría derivar en interrupciones de servicio no detectadas o riesgos directos para la seguridad del paciente.

IV-C. Experimento 3: Estrategia de Defensa mediante Balanceo

Los resultados validan que la aplicación conjunta de submuestreo (RUS) y sobremuestreo (SMOTE) para equilibrar el dataset antes del envenenamiento actúa como una contramedida de endurecimiento (hardening) altamente efectiva. Al entrenarse en un espacio de clases balanceado, se fuerzan vectores de soporte y fronteras de decisión mucho más nítidas y robustas, permitiendo a los modelos ignorar el ruido masivo.

Observando la Fig. 1, vemos que la recuperación de los algoritmos bajo este enfoque es sobresaliente. Bajo un 10 % de envenenamiento severo, XGBoost recupera un rendimiento óptimo, alcanzando un 0.99 en Accuracy, Precision, Recall y F1-Score. Además, logra tasas de detección superiores al 99.72 % para aquellas clases minoritarias que en el Exp. 2 resultaban indetectables. Incluso el Random Forest (RF), que había fallado notablemente en el experimento previo, logra escalar su F1-Score hasta un 0.9439.

Para llevar los modelos a sus umbrales críticos de ruptura, se evaluaron tasas extremas de envenenamiento de hasta el 50 %. Mientras que las arquitecturas basadas en árboles más simples (DT y RF) sufren un colapso sistémico a partir del




Figura 1. F1-Score de los modelos entre el Exp. 2 (Distribution-Preserving - Sin Defensa) y Exp. 3 (Distribution-Preserving - Con Defensa).

40 % de veneno (alcanzando pérdidas de robustez superiores al 52 % al llegar al 50 %), los modelos más complejos (XGB y FNN) mantienen una inmunidad casi total. Sorprendentemente, con la mitad de las etiquetas corruptas en el entrenamiento, XGB y FNN registran un RL en su F1-Score de apenas 0.73 % y 0.59 %, respectivamente.

En síntesis, estos hallazgos sugieren que la elección de una arquitectura algorítmica avanzada (XGB) combinada con el balanceo de clases no debe verse solo como una optimización de rendimiento, sino como una contramedida defensiva esencial para garantizar la robustez y disponibilidad de los IDS en redes IoMT críticas.

V. CONCLUSIONES Y LÍNEAS FUTURAS

La expansión del ecosistema IoMT exige Sistemas de Detección de Intrusiones (IDS) que no solo sean ligeros, sino altamente resilientes frente a manipulaciones adversarias. Este estudio demuestra que un alto rendimiento en condiciones ideales no garantiza la seguridad: los ataques de envenenamiento de etiquetas que preservan la distribución de clases (*distribution-preserving*) resultan devastadores, logrando una degradación del rendimiento (*Robustness Loss*) de hasta el 54.52 % en modelos simples. No obstante, se ha validado que la arquitectura algorítmica y el preprocesamiento son factores determinantes para la seguridad. La aplicación de un balanceo híbrido (RUS + SMOTE) actúa como una técnica de endurecimiento (*hardening*) excepcional. Bajo esta estrategia defensiva, el modelo XGBoost se consolida como la solución superior, recuperando una eficiencia del 99 % (*Accuracy, Precision, Recall* y *F1-Score*) frente a ataques convencionales, y manteniendo una pérdida de robustez inferior al 1 % incluso ante tasas de envenenamiento extremas del 50 %. Por el contrario, los algoritmos basados en árboles simples (DT y RF) sufren un colapso sistémico superado el umbral del 40 % de corrupción de datos.

Como líneas de trabajo futuro, se explorarán modalidades de ataque que manipulen las características de los datos (*Clean-label Poisoning*), la evaluación de la vulnerabilidad frente a ataques de evasión en la fase de inferencia y el desarrollo de estrategias de defensa mediante entrenamiento adversarial en redes federadas.

Tabla I
RESULTADOS DE LA MÉTRICA *Robustness Loss* DEL EXP. 2 Y 3 UTILIZANDO DISTINTAS TASAS DE CAMBIO DE ETIQUETAS.

Experiment	Label Flipping Rate	Modelo	$RL_{accuracy}$	$RL_{precision}$	RL_{recall}	$RL_{f1-score}$
Exp. 2	1 %	DT	0.02±0.01 %	0.23±0.10 %	0.87±0.36 %	0.37±0.21 %
		RF	0.16±0.01 %	0.78±0.11 %	4.60±0.26 %	3.12±0.20 %
		XGB	0.01±0.00 %	0.03±0.06 %	0.19±0.04 %	0.11±0.04 %
		FNN	0.02±0.02 %	-0.01±0.20 %	0.43±0.25 %	0.22±0.12 %
	5 %	DT	0.61±0.01 %	21.87±0.07 %	21.52±0.10 %	21.70±0.05 %
		RF	1.35±0.01 %	23.06±0.06 %	25.10±0.11 %	24.17±0.06 %
		XGB	0.64±0.00 %	23.90±0.33 %	22.24±0.03 %	23.09±0.20 %
		FNN	0.64±0.04 %	23.49±0.35 %	22.11±0.16 %	22.83±0.20 %
	10 %	DT	7.17±0.08 %	29.18±1.38 %	54.52±0.42 %	54.20±0.68 %
		RF	7.08±0.02 %	31.72±0.47 %	51.05±0.11 %	47.44±0.14 %
		XGB	0.67±0.01 %	23.98±0.12 %	22.44±0.05 %	23.23±0.08 %
		FNN	0.66±0.02 %	23.75±0.54 %	22.25±0.17 %	22.81±0.31 %
Exp. 3	1 %	DT	0.01±0.02 %	0.05±0.26 %	0.01±0.08 %	0.03±0.17 %
		RF	0.09±0.01 %	0.87±0.12 %	0.11±0.05 %	0.49±0.07 %
		XGB	0.01±0.00 %	0.17±0.12 %	0.01±0.02 %	0.09±0.06 %
		FNN	-0.02±0.02 %	-0.25±0.32 %	-0.11±0.11 %	-0.18±0.18 %
	5 %	DT	0.01±0.02 %	0.03±0.20 %	0.01±0.08 %	0.02±0.13 %
		RF	0.53±0.03 %	4.49±0.25 %	0.71±0.05 %	2.74±0.16 %
		XGB	0.02±0.00 %	0.27±0.13 %	0.02±0.04 %	0.15±0.08 %
		FNN	0.00±0.00 %	-0.02±0.49 %	-0.11±0.14 %	-0.06±0.26 %
	10 %	DT	0.02±0.02 %	0.02±0.26 %	0.04±0.08 %	0.03±0.16 %
		RF	1.19±0.04 %	8.11±0.30 %	1.57±0.07 %	5.30±0.20 %
		XGB	0.02±0.01 %	0.33±0.13 %	0.03±0.04 %	0.18±0.08 %
		FNN	-0.01±0.02 %	-0.16±0.35 %	-0.14±0.12 %	-0.15±0.19 %
	20 %	DT	0.03±0.01 %	0.11±0.26 %	0.05±0.08 %	0.08±0.16 %
		RF	3.27±0.04 %	13.86±0.23 %	4.55±0.11 %	10.46±0.16 %
		XGB	0.03±0.01 %	0.47±0.16 %	0.05±0.03 %	0.26±0.09 %
		FNN	0.07±0.06 %	1.13±1.00 %	0.06±0.18 %	0.84±0.58 %
	30 %	DT	0.05±0.02 %	0.08±0.27 %	0.11±0.07 %	0.09±0.16 %
		RF	7.47±0.06 %	19.05±0.23 %	11.01±0.20 %	17.07±0.15 %
		XGB	0.04±0.00 %	0.63±0.17 %	0.07±0.03 %	0.35±0.09 %
		FNN	0.03±0.05 %	0.46±0.46 %	0.08±0.34 %	0.29±0.37 %
	40 %	DT	0.12±0.03 %	-0.18±0.32 %	0.57±0.16 %	0.15±0.19 %
		RF	15.53±0.06 %	25.00±0.20 %	24.76±0.32 %	27.79±0.17 %
		XGB	0.05±0.01 %	0.88±0.24 %	0.11±0.04 %	0.50±0.14 %
		FNN	0.01±0.02 %	0.31±0.34 %	-0.02±0.13 %	0.16±0.20 %
	50 %	DT	61.12±17.87 %	10.67±7.75 %	59.13±9.79 %	52.67±9.01 %
		RF	57.57±18.99 %	36.79±0.78 %	56.97±4.19 %	53.33±4.12 %
		XGB	0.09±0.01 %	1.24±0.22 %	0.19±0.04 %	0.73±0.12 %
		FNN	0.07±0.05 %	1.03±0.76 %	0.09±0.20 %	0.59±0.43 %

AGRADECIMIENTOS

Investigación posible gracias al programa predoctoral AGAUR-FI Ajuts Joan Oró (2024 FI-1 00643) Ajuts Joan Oró (Generalitat de Catalunya) y de la Cátedra de Ciberseguridad CARISMATICA financiada por la UE e INCIBE.

REFERENCIAS

- [1] A. Nasayreh, H. M. Khalid, H. K. Alkhateeb, J. Al-Manaseer, A. Ismail, and H. Gharaibeh, "Automated detection of cyber attacks in healthcare systems: A novel scheme with advanced feature extraction and classification," *Computers & Security*, vol. 150, p. 104288, 2025.
- [2] S. B. Weber, S. Stein, M. Pilgermann, and T. Schrader, "Attack detection for medical cyber-physical systems-a systematic literature review," *IEEE Access*, vol. 11, pp. 41 796–41 815, 2023.
- [3] J. Doménech, I. V. Martin-Faus, S. Mhiri, and J. Pegueroles, "Ensuring patient safety in iomt: A systematic literature review of behavior-based intrusion detection systems," *Internet of Things*, vol. 28, p. 101420, 2024. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S2542660524003615>
- [4] S. Dadkhah, E. C. P. Neto, R. Ferreira, R. C. Molokwu, S. Sadeghi, and A. A. Ghorbani, "Ciciomt2024: A benchmark dataset for multi-protocol security assessment in iomt," *Internet of Things*, vol. 28, p. 101351, 2024.
- [5] J. Areia, I. A. Bispo, L. Santos, and R. L. d. C. Costa, "Iomt-trafficedata: Dataset and tools for benchmarking intrusion detection in internet of medical things," *IEEE Access*, vol. 12, pp. 115 370–115 385, 2024.
- [6] A. Oprea, A. Singhal, and A. Vassilev, "Poisoning attacks against machine learning: Can machine learning be trustworthy?" *Computer*, vol. 55, no. 11, pp. 94–99, 2022.
- [7] Z. Tian, L. Cui, J. Liang, and S. Yu, "A comprehensive survey on poisoning attacks and countermeasures in machine learning," *ACM Comput. Surv.*, vol. 55, no. 8, Dec. 2022. [Online]. Available: <https://doi.org/10.1145/3551636>
- [8] C. Dunn, N. Moustafa, and B. Turnbull, "Robustness evaluations of sustainable machine learning models against data poisoning attacks in the internet of things," *Sustainability*, vol. 12, no. 16, 2020. [Online]. Available: <https://www.mdpi.com/2071-1050/12/16/6434>
- [9] A. Alajaji, "Fortinids: Defending smart city iot infrastructures against transferable adversarial poisoning in machine learning-based intrusion detection systems," *Sensors*, vol. 25, no. 19, 2025. [Online]. Available: <https://www.mdpi.com/1424-8220/25/19/6056>
- [10] M. Akhi, C. Eising, and L. L. Dhirani, "Residual temporal cnns for emerging cyber threat detection in healthcare iot," *Discover Internet of Things*, vol. 6, no. 1, p. 12, 2026.
- [11] B. Ali, M. Gunavathie, P. Karthigaikumar *et al.*, "Secure iot medical data storage and intrusion detection using blockchain encryption and optimized two-branch attention adversarial transformer," *Biomedical Materials & Devices*, pp. 1–26, 2025.
- [12] E. Bhuvaneswari, G. Uthradevi, A. M. J. Kinol, and P. Shanthi, "Edgeguardedmed: Transformer-based intrusion detection with packet-flow fusion for resilient iomt," *Biomedical Materials & Devices*, pp. 1–12, 2025.
- [13] M. Fahim-Ul-Islam, A. Chakrabarty, M. G. R. Alam, and S. S. Maidin, "A resource-efficient federated learning framework for intrusion detection in iomt networks," *IEEE Transactions on Consumer Electronics*, 2025.
- [14] J. Doménech, O. León, M. S. Siddiqui, and J. Pegueroles, "Evaluating and enhancing intrusion detection systems in iomt: The importance of domain-specific datasets," *Internet of Things*, vol. 32, p. 101631, 2025.

Applicability of adversarial attacks in machine learning based NIDSs: A preliminary analysis

Joaquín Gaspar Medina-Arco Roberto Magán-Carrión Rafael A. Rodríguez-Gómez*

Network Engineering & Security Group (NESG)

Research Centre for Information and Communication Technologies (CITIC-UGR), University of Granada, Granada, Spain.

jgasparmedina@correo.ugr.es, rmagan@ugr.es, rafa@rti.com

**Formerly Universidad de Granada, currently Real-Time Innovations (RTI) – Connex Security Team.*

Abstract—Network intrusion detection systems (NIDSs) have become a primary security mechanism against cyber-attacks and attempts to gain improper access to systems. The growth of computing and the application of artificial intelligence have enhanced the robustness of NIDSs, enabling them to detect even zero-day threats or attacks through the incorporation of machine learning and anomaly detection models. However, these models have, in turn, become the target of attacks, whereby adversarial attack techniques are applied with the aim of nullifying their operation or reducing their effectiveness sufficiently so as not to detect an attack. This paper presents a preliminary study of adversarial attack techniques applied to machine learning-based NIDSs, with a particular focus on their applicability in a real production environment. To this end, i) an introduction to the different types of adversarial attack currently in existence is conducted, and ii) a preliminary assessment of the applicability of these adversarial attacks in a real-world environment is carried out as a preview of a more extensive work in progress.

Index Terms—artificial intelligence, network intrusion detection systems, adversarial attacks, anomaly detection, computer networks

Contribution type: *Ongoing work*

I. INTRODUCTION

The last decade has witnessed an unprecedented expansion in the domain of Artificial Intelligence (AI), driven by the exponential growth of computational power and the availability of massive datasets. This evolution has positioned Machine Learning (ML) and Deep Learning (DL) not merely as auxiliary tools, but as core components in processing vast amounts of information and uncovering intricate non-linear relationships within data [1]. Consequently, the field of cybersecurity has rapidly assimilated these advancements, integrating DL models across the entire security spectrum established by NIST [2], [3]. While these applications range from malware analysis [4] to phishing detection [5], their impact is particularly profound in the realm of Network Intrusion Detection Systems (NIDSs) [6].

NIDSs constitute the backbone of modern network defense strategies. Acting as the primary surveillance mechanism for Security Operations Centers (SOCs), they are tasked with monitoring network traffic to identify illegitimate access attempts, vulnerabilities, and active threats. Historically, NIDSs relied on signature-based methods, such as the widely deployed Snort [7], which compare traffic against a database of known attack fingerprints. However, the dynamic nature of modern cyber threats has rendered signature-based approaches insufficient against novel, unseen attacks. This limitation has spurred the transition towards anomaly-based NIDS (e.g., Kitsune [8]), which leverage ML to model “normal” network

behavior. By identifying statistical deviations from this baseline, ML-based NIDS can effectively detect zero-day attacks without prior knowledge of the specific threat signature.

Despite their effectiveness, ML-based NIDSs introduce a critical vulnerability: Adversarial Machine Learning (AML) [9]. Adversaries manipulate network traffic to deceive these models [10] across two primary lifecycle stages [11], [12]. During the training phase, poisoning attacks inject malicious data to corrupt decision boundaries and create permanent backdoors. Conversely, during the inference phase, evasion attacks minimally perturb malicious packets to bypass detection without altering the model, critically preserving the payload’s original functionality.

However, a significant dichotomy exists in current research. While numerous studies have demonstrated the theoretical effectiveness of adversarial attacks against NIDS [13], [14], there is a scarcity of research addressing their practical viability in real-world production environments. Network traffic differs fundamentally from images; it is heterogeneous, high-dimensional, and encompasses strict constraints on protocol validity and temporal causality. Crafting an adversarial packet that deceives a generic ML model is computationally feasible, but ensuring that same packet remains valid, routable, and malicious within a real network infrastructure presents a much higher complexity barrier. Recent critical reviews have begun to question the applicability of these academic attacks in operational settings [15], suggesting that the threat landscape may be overstated without considering the specific constraints of the cybersecurity domain [16].

This paper addresses this gap by presenting a Work in Progress (WiP) survey that critically evaluates the state of the art of adversarial attacks on NIDS from a pragmatic perspective. Unlike previous surveys that focus solely on algorithmic success rates ([13], [17]), this work aims to reflect on the feasibility or effective usefulness of an adversary attack in the field of NIDS.

II. NIDSs’ ECOSYSTEM

This section introduces the NIDS ecosystem, covering AI-based detection techniques (ML and DL), the network datasets used as model inputs, and the current state of the art in ML/DL-based NIDS.

A. ML- and DL-based NIDSs

Machine Learning (ML) is a subfield of artificial intelligence (AI) that utilizes algorithms based on computational statistics to learn and infer knowledge from datasets where

relationships are not immediately apparent [18]. Deep Learning (DL) is a specialization within ML that mimics the neural connections of the human brain to achieve superior correlation and training outcomes in many fields including cybersecurity [19], [20]. In the context of NIDS, DL-based solutions have shown superior performance because traditional ML models are more susceptible to higher false positive ratios [21].

The application of these techniques can be supervised, unsupervised, or semi-supervised, depending on whether the training data is labeled or not. Throughout the following sections both ML and DL algorithms widely-adopted in NIDSs are introduced.

B. ML and DL Methods

In recent years, NIDS have evolved significantly to cope with the growing complexity and volume of network traffic. Initially, solutions relied on traditional ML algorithms, such as Support Vector Machines (SVM) [22], K-Nearest Neighbours (KNN) [23], Random Forest (RF) [24], decision trees (DT) [25] and K-means [26]. The efficacy of these classical methods in extracting surface-level features and classifying known threats in controlled environments has been well-documented.

However, the need to detect more complex underlying patterns and zero-day attacks has driven the adoption of deep learning (DL) techniques. Deep architectures, including Recurrent Neural Networks (RNN) [27], Convolutional Neural Networks (CNN) [28], and Autoencoders (AE) [29], have superseded numerous limitations of conventional methods. By enabling the automatic extraction of hierarchical features and the efficient modelling of sequential or non-linear data, DL has established itself as the current standard for the development of more robust, adaptable NIDS with higher detection rates against sophisticated intrusions.

C. Network Datasets

The training and evaluation of ML and DL models applied to NIDS necessitate the utilisation of appropriately sized, representative and labelled datasets. The usefulness of a network traffic dataset is defined by key characteristics such as its generation method (synthetic, real or hybrid), the data format (raw packets, flow records or pre-extracted features), class balance and the temporal nature of the captures. Table I presents a comprehensive summary of the most relevant datasets analysed in the literature, classifying them according to the aforementioned parameters.

Historically, research into NIDS relied heavily on foundational and synthetic datasets, including DARPA, KDD99 and NSL-KDD. Nevertheless, the reliability of these classic datasets has been subject to considerable scrutiny due to three primary factors. Firstly, the traffic patterns depicted are no longer representative of current networks. Secondly, there is a lack of representativeness with regard to contemporary networks. Thirdly, there are statistical biases inherent in the datasets. In order to overcome these limitations, there has been a shift towards the adoption of datasets that capture real-world dynamics or more complex hybrid infrastructures. Contemporary alternatives, including Kyoto 2006+, UGR'16,

UNSW-NB15 and the recent CIC datasets (e.g. CSE-CIC-IDS2018 or CIC-DDoS2019), have been shown to reflect contemporary protocols and new threats with a higher degree of accuracy. These alternatives provide far more realistic validation environments for modern cyberattacks.

D. Ready-to-use NIDSs

In terms of practical implementation, recent literature proposes various NIDS solutions that integrate the ML and DL models described above. Among the hybrid approaches, SVM-KNN-PSO is a notable example, integrating conventional classifiers with heuristic optimisation techniques to enhance detection accuracy [43], along with proposals such as Multi-level NIDS, which employs a hierarchical, multi-stage classification to analyse traffic [44]. In the domain of Deep Learning, advanced tools such as Kitsune [8] are noteworthy. This is a plug-and-play NIDS that employs an ensemble of unsupervised autoencoders for real-time anomaly detection without human intervention, or AE-IDS, which adapts this same unsupervised framework to operate efficiently in a distributed manner [45]. It is imperative to understand the architecture of these operating systems to facilitate the research effort, as the feature extraction and model evaluation phases represent the predominant attack surface for adversarial traffic injection.

III. ADVERSARIAL ATTACKS

The study of vulnerabilities in machine learning algorithms has a long history, having gained particular traction following demonstrations of the fragility of deep neural networks (DNNs) in the field of computer vision. In this domain, minute and imperceptible disturbances have been shown to drastically alter the classification of an image (see, for example, Szegedy et al. [46]). However, the direct transposition of these adversarial techniques to the field of cybersecurity (and in particular, to NIDS) presents fundamental constraints.

In contrast to the image domain, where pixel values are continuous and can be modified with great spatial freedom, the manipulation of network traffic is a discrete and highly restrictive process. The perturbations introduced by the attacker are strictly limited by the specifications of network protocols (TCP/IP), the format of headers and, most critically, the unavoidable need to preserve the original functionality of the cyberattack and the semantics of the communication [14], [47]. It is evident that the generation of viable and executable adversarial traffic in a real-world environment necessitates a significantly more intricate approach than the straightforward addition of mathematical noise.

An adversarial attack is a deliberate attempt to deceive an ML model by creating adversarial examples (x'), which are input data modified by a minimal perturbation (δ). Within the framework of NIDS, this perturbation does not equate to mere mathematical noise; rather, it constitutes a deliberate modification that must adhere to the semantics and constraints of network protocols in order to maintain the functionality of the malicious payload without being detected [14], [10], [47], [48]. The purpose of these perturbations is usually to compromise the fundamental pillars of the model, such as its integrity (through inference evasion or training poisoning

Table I: Main features of analysed network traffic datasets

Dataset	Type	Format	Class Balance	Capture Duration	Dates
DARPA [30]	synthetic	packets	no	7 weeks	1998–1999
KDD99 [31]	synthetic	features	no	N.S.	1998–1999
NSL-KDD [32]	synthetic	features	yes	N.S.	2009
Kyoto 2006+ [33]	real	features	yes	9 years	2006–2015
Botnet [34]	synthetic	packets	yes	N.S.	2010–2014
UNSW-NB15 [35]	synthetic	packets	no	31 hours	2015
UGR'16 [36]	real	flows	no	6 months	2016
CIC-IDS2017 [37]	synthetic	flows	no	5 days	2017
CSE-CIC-IDS2018 [38]	synthetic	flows	no	15 days	2018
CIC-DDoS2019 [39]	real	flows	no	2 days	2019
NF-UQ-NIDS [40]	synthetic	flows	no	N.S.	2021
CCD-IDSv1 [41]	synthetic	features	no	N.S.	2021
CCD-INIDv1 [42]	synthetic	features	no	N.S.	2021

* N.S. – Not Specified.

techniques [49], [21], its availability (causing denial of service [49], [47]) or its privacy (reconstructing sensitive data from the training phase [21]).

IV. RELATED WORKS

Recent literature has addressed the Adversarial Machine Learning (AML) paradigm from various perspectives. Pioneering works such as those by Pitropakis et al. [50], Duddu [52] [49] and Thomas et al. [48] provide comprehensive taxonomies and didactic frameworks for attack techniques. However, as the primary focus of these methodologies is on continuous domains such as computer vision, there is a lack of direct applicability to the discrete constraints of network protocols. In order to address the specificities of cybersecurity, authors such as Rosenberg et al. [47] and Malik et al. [51] have adapted these taxonomies, linking theoretical research to real-world incidents and highlighting practical limitations in domains such as malware and NIDS.

In the specific field of NIDS, the comprehensive analysis by He et al. [13] establishes a crucial and necessary distinction between feature-level attacks (theoretical and centred on mathematical vectors) and packet-level attacks (practical but highly complex to generate). When considered as a whole, and with further support from analyses of the operational context of cyber-physical systems [17], the state of the art reveals a central conflict: whilst the theoretical framework of AML is mature, there remains a significant research gap in the systematic evaluation of packet-level attacks that manage to evade detection whilst simultaneously preserving the functionality of malicious code in operational networks.

V. CONCLUSIONS AND FUTURE WORK

The literature review traces a clear evolutionary trajectory: from the architecture of classic NIDS to the sophistication of ML-based models, an advance that has ushered in a new era of vulnerabilities through adversarial machine learning. The current state of the art reveals a central and still unresolved conflict: while the academic community has achieved remarkable maturity in generating theoretical attacks at the feature level, which manipulate abstract mathematical representations of data, the domain of practical and functional attacks at the packet level remains insufficiently explored. This gap is critical, as the ability to attack a numerical vector does not guarantee the ability to generate malicious, functional, and

protocol-compliant network traffic. Most proposed defences, therefore, have been developed against a theoretical threat that may be irrelevant against a real adversary. The fundamental and unresolved challenge that defines the frontier of this research is the systematic development of packet-level attacks and defences that simultaneously consider evasiveness, preservation of malice, and the complex constraints of the network domain.

As a continuation of this ongoing work, and in order to complete the scope, a detailed analysis of the state of the art associated with adversarial attacks applied to ML-based NIDS is proposed. In this analysis, an objective taxonomy could be proposed, with the following criteria being taken into consideration: the validity of the proposed technique, the attacker's knowledge of the model, the phase of the model's life cycle that is being attacked (MLOps), and whether it has faced any state-of-the-art NIDS, among others. The establishment of metrics for measuring the applicability of each technique in real-world scenarios would be a significant achievement.

ACKNOWLEDGEMENTS

This publication has been mainly funded by MICIN/AEI/10.13039/501100011033 under grants PID2024-161902OB-I00 and by the project NetSEA-GPT (C-ING-300-UGR23) funded by Consejería de Universidad, Investigación e Innovación and the European Union through the ERDF Andalusia Program 2021-2027.

REFERENCES

- [1] Y. Lecun, Y. Bengio, and G. Hinton, "Deep learning," *Nature* 2015 521:7553, vol. 521, pp. 436–444, 5 2015.
- [2] M. Barrett, "Framework for improving critical infrastructure cybersecurity, version 1.1," 4 2018.
- [3] R. Kaur, D. Gabrijelčič, and T. Klobučar, "Artificial intelligence for cybersecurity: Literature review and future research directions," *Information Fusion*, vol. 97, p. 101804, 9 2023.
- [4] M. J. Hossain, H. Shahrar, M. Valero, F. L. Barsha, S. Sobhan, M. A. Khan, M. Whitman, A. Cuzzocrea, D. Lo, A. Rahman, and F. Wu, "Malware detection and prevention using artificial intelligence techniques," in *IEEE International Conference on Big Data (Big Data)*. IEEE, 12 2021, pp. 5369–5377.
- [5] A. Karim, S. Azam, B. Shanmugam, K. Kannoorpatti, and M. Alazab, "A comprehensive survey for intelligent spam email detection," *IEEE Access*, vol. 7, pp. 168 261–168 295, 2019.
- [6] N. Chaabouni, M. Mosbah, A. Zemmari, C. Sauvignac, and P. Faruki, "Network intrusion detection for iot security based on learning techniques," *IEEE Communications Surveys and Tutorials*, vol. 21, pp. 2671–2701, 2019, conference Name: IEEE Communications Surveys and Tutorials.

- [7] R. U. Rehman, *Intrusion detection systems with Snort : advanced IDS techniques using Snort, Apache, MySQL, PHP, and ACID*. Prentice Hall PTR, 2003.
- [8] Y. Mirsky, T. Doitshman, Y. Elovici, and A. Shabtai, "Kitsune: An ensemble of autoencoders for online network intrusion detection," *25th Annual Network and Distributed System Security Symposium, NDSS 2018*, 2 2018.
- [9] W. Zhao, S. Alwidian, and Q. H. Mahmoud, "Adversarial training methods for deep learning: A systematic review," *Algorithms*, vol. 15, p. 283, 8 2022.
- [10] A. Chakraborty, M. Alam, V. Dey, A. Chattopadhyay, and D. Mukhopadhyay, "A survey on adversarial attacks and defences," *CAAI Transactions on Intelligence Technology*, vol. 6, pp. 25–45, 3 2021.
- [11] R. Ashmore, R. Calinescu, and C. Paterson, "Assuring the machine learning lifecycle," *ACM Computing Surveys*, vol. 54, pp. 1–39, 6 2022.
- [12] M. Lucia and C. Cotton, "Adversarial machine learning for cyber security," *Journal of Information Systems Applied Research*, vol. 12, p. 26, 4 2019. [Online]. Available: <http://jisar.org/2019-12/n1/JISARv12n1p26.html>
- [13] K. He, D. D. Kim, and M. R. Asghar, "Adversarial machine learning for network intrusion detection systems: A comprehensive survey," *IEEE Communications Surveys and Tutorials*, vol. 25, pp. 538–566, 2023.
- [14] E. Alshahrani, D. Alghazzawi, R. Alotaibi, and O. Rabie, "Adversarial attacks against supervised machine learning based network intrusion detection systems," *PLOS ONE*, vol. 17, p. e0275971, 10 2022.
- [15] D. Arp, E. Quiring, F. Pendlebury, A. Warnecke, F. Pierazzi, C. Wressnegger, L. Cavallaro, and K. Rieck, "Dos and don'ts of machine learning in computer security," *arXiv*, 10 2020.
- [16] G. Apruzzese, M. Andreolini, L. Ferretti, M. Marchetti, and M. Colajanni, "Modeling realistic adversarial attacks against network intrusion detection systems," *Digital Threats: Research and Practice*, vol. 3, p. 31:1–31:19, 2 2022.
- [17] A. Humayed, J. Lin, F. Li, and B. Luo, "Cyber-physical systems security—a survey," *IEEE Internet of Things Journal*, vol. 4, pp. 1802–1831, 12 2017, mAG ID: 2579603034.
- [18] Y. Xin, L. Kong, Z. Liu, Y. Chen, Y. Li, H. Zhu, M. Gao, H. Hou, and C. Wang, "Machine learning and deep learning methods for cybersecurity," *IEEE Access*, vol. 6, pp. 35 365–35 381, 2018.
- [19] A. L. Buczak and E. Guven, "A survey of data mining and machine learning methods for cyber security intrusion detection," *IEEE Communications Surveys and Tutorials*, vol. 18, pp. 1153–1176, 2016.
- [20] Z. Ahmad, A. S. Khan, C. W. Shiang, J. Abdullah, and F. Ahmad, "Network intrusion detection system: A systematic study of machine learning and deep learning approaches," *Transactions on Emerging Telecommunications Technologies*, vol. 32, p. e4150, 2021.
- [21] N. Alhussien, A. Aleroud, A. Melhem, and S. Y. Khamaiseh, "Constraining adversarial attacks on network intrusion detection systems: Transferability and defense analysis," *IEEE Transactions on Network and Service Management*, vol. 21, pp. 2751–2772, 2024.
- [22] E. A. Shams and A. Rizaner, "A novel support vector machine based intrusion detection system for mobile ad hoc networks," *Wireless Networks*, vol. 24, pp. 1821–1829, 7 2018.
- [23] A. I. Saleh, F. M. Talaat, and L. M. Labib, "A hybrid intrusion detection system (hids) based on prioritized k-nearest neighbors and optimized svm classifiers," *Artificial Intelligence Review*, vol. 51, pp. 403–443, 3 2019.
- [24] J. Zhang, M. Zulkernine, and A. Haque, "Random-forests-based network intrusion detection systems," *IEEE Transactions on Systems, Man and Cybernetics Part C: Applications and Reviews*, vol. 38, pp. 649–659, 2008.
- [25] M. Kumar, M. Hanumanthappa, and T. V. Kumar, "Intrusion detection system using decision tree algorithm," *International Conference on Communication Technology Proceedings, ICCT*, pp. 629–634, 2012.
- [26] Y. Y. Aung and M. M. Min, "An analysis of k-means algorithm based network intrusion detection system," *Advances in Science, Technology and Engineering Systems Journal*, vol. 3, pp. 496–501, 2 2018.
- [27] C. Xu, J. Shen, X. Du, and F. Zhang, "An intrusion detection system using a deep neural network with gated recurrent units," *IEEE Access*, vol. 6, pp. 48 697–48 707, 8 2018.
- [28] H. C. Altunay and Z. Albayrak, "A hybrid cnn+lstm-based intrusion detection system for industrial iot networks," *Engineering Science and Technology, an International Journal*, vol. 38, p. 101322, 2 2023.
- [29] Y. Song, S. Hyun, and Y. G. Cheong, "Analysis of autoencoders for network intrusion detection," *Sensors 2021, Vol. 21, Page 4294*, vol. 21, p. 4294, 6 2021.
- [30] R. Lippmann, J. W. Haines, D. J. Fried, J. Korba, and K. Das, "The 1999 darpa off-line intrusion detection evaluation," *Computer Networks*, vol. 34, pp. 579–595, 10 2000.
- [31] W. F. S. Stolfo, "Kdd cup 1999 data," 1999.
- [32] M. Tavallae, E. Bagheri, W. Lu, and A. A. Ghorbani, "A detailed analysis of the kdd cup 99 data set," in *2009 IEEE Symposium on Computational Intelligence for Security and Defense Applications*, 7 2009, pp. 1–6, iSSN: 2329-6275.
- [33] J. Song, H. Takakura, Y. Okabe, M. Eto, D. Inoue, and K. Nakao, "Statistical analysis of honeypot data and building of kyoto 2006+ dataset for nids evaluation," in *Proceedings of the First Workshop on Building Analysis Datasets and Gathering Experience Returns for Security*. Association for Computing Machinery, 4 2011, pp. 29–36.
- [34] E. B. Beigi, H. H. Jazi, N. Stakhanova, and A. A. Ghorbani, "Towards effective feature selection in machine learning-based botnet detection approaches," in *2014 IEEE Conference on Communications and Network Security*, 10 2014, pp. 247–255.
- [35] N. Moustafa and J. Slay, "Unsw-nb15: a comprehensive data set for network intrusion detection systems (unsw-nb15 network data set)," in *2015 Military Communications and Information Systems Conference (MilCIS)*, 11 2015, pp. 1–6.
- [36] G. Maciá-Fernández, J. Camacho, R. Magán-Carrión, P. García-Teodoro, and R. Therón, "Ugr'16: A new dataset for the evaluation of cyclostationarity-based network idss," *Computers and Security*, vol. 73, pp. 411–424, 3 2018.
- [37] I. Sharafaldin, A. H. Lashkari, and A. A. Ghorbani, "Toward generating a new intrusion detection dataset and intrusion traffic characterization," in *Proceedings of the 3rd ACM CoNEXT Workshop on Big Data, Machine Learning and Artificial Intelligence for Data Communication Networks*, 11 2018, pp. 108–116.
- [38] C. I. for Cybersecurity, "Cse-cic-ids2018," <https://www.unb.ca/cic/datasets/ids-2018.html>, 2018, accessed: 2023-11-30.
- [39] I. Sharafaldin, A. H. Lashkari, S. Hakak, and A. A. Ghorbani, "Developing realistic distributed denial of service (ddos) attack dataset and taxonomy," in *2019 International Carnahan Conference on Security Technology (ICCST)*, 2019, pp. 1–8.
- [40] M. Sarhan, S. Layeghy, N. Moustafa, and M. Portmann, "Netflow datasets for machine learning-based network intrusion detection systems," in *Big Data Technologies and Applications*, Z. Deze, H. Huang, R. Hou, S. Rho, and N. Chilamkurti, Eds. Springer International Publishing, 2021, pp. 117–135.
- [41] N. Thapa, Z. Liu, A. Shaver, A. Esterline, B. Gokaraju, and K. Roy, "Secure cyber defense: An analysis of network intrusion-based dataset ccd-idsv1 with machine learning and deep learning models," *Electronics*, vol. 10, no. 15, 2021. [Online]. Available: <https://www.mdpi.com/2079-9292/10/15/1747>
- [42] Z. Liu, N. Thapa, A. Shaver, K. Roy, M. Siddula, X. Yuan, and A. Yu, "Using embedded feature selection and cnn for classification on ccd-inid-v1—a new iot dataset," *Sensors*, vol. 21, no. 14, 2021. [Online]. Available: <https://www.mdpi.com/1424-8220/21/14/4834>
- [43] J. Kennedy, *Swarm Intelligence*. Boston, MA: Springer US, 2006, ch. 6, pp. 187–219.
- [44] W. L. Al-Yaseen, Z. A. Othman, and M. Z. A. Nazri, "Multi-level hybrid support vector machine and extreme learning machine based on modified k-means for intrusion detection system," *Expert Systems with Applications*, vol. 67, pp. 296–303, 2017.
- [45] X. Li, W. Chen, Q. Zhang, and L. Wu, "Building auto-encoder intrusion detection system based on random forest feature selection," *Computers & Security*, vol. 95, p. 101851, 2020.
- [46] C. Szegedy, W. Zaremba, I. Sutskever, J. Bruna, D. Erhan, I. Goodfellow, and R. Fergus, "Intriguing properties of neural networks," 2014. [Online]. Available: <https://arxiv.org/abs/1312.6199>
- [47] I. Rosenberg, A. Shabtai, Y. Elovici, and L. Rokach, "Adversarial machine learning attacks and defense methods in the cyber security domain," *ACM Computing Surveys*, vol. 54, p. 108:1–108:36, 5 2021.
- [48] T. Thomas, A. P. Vijayaraghavan, and S. Emmanuel, *Adversarial Machine Learning in Cybersecurity*. Springer Singapore, 2020, pp. 185–200.
- [49] V. Duddu, "A survey of adversarial machine learning in cyber warfare," *Defence Science Journal*, vol. 68, p. 356, 6 2018.
- [50] N. Pitropakis, E. Panaousis, T. Giannetos, E. Anastasiadis, and G. Loukas, "A taxonomy and survey of attacks against machine learning," *Computer Science Review*, vol. 34, p. 100199, 11 2019. [Online]. Available: <https://www.sciencedirect.com/science/article/abs/pii/S1574013718303289>
- [51] J. Malik, R. Muthalagu, and P. M. Pawar, "A systematic review of adversarial machine learning attacks, defensive controls, and technologies," *IEEE Access*, vol. 12, pp. 99 382–99 421, 2024.

A Review of: Advanced detection of suspicious activity within UEBA framework using Deep Autoencoders

Jose Fuentes*, Ines Ortega-Fernandez*, Nora M. Villanueva^{†‡}, Marta Sestelo^{†‡}

*Galician Research and Development Centre for Advanced Telecommunications (GRADIANT), 36214 Vigo, Spain

[†]Galician Center for Mathematical Research and Technology (CITMAga), 15782 Santiago de Compostela, Spain

[‡]Universidade de Vigo, Department of Statistics and O.R. & SiDOR Group, 36310 Vigo, Spain

Abstract—The exponential growth of interconnected devices, the increasing volume of sensitive data, and the complexity of technological infrastructures, highlight the need for applying techniques that ensure cybersecurity. User and Entity Behaviour Analytics (UEBA) attempts to model normal activity to detect security threats. Among the techniques used to detect anomalies, Deep Autoencoders (AE) constitute one of the most promising deep learning models on UEBA tasks, allowing early detection of security incidents that could lead to the leaking of personal data, hijacking of systems, or access to sensitive business information. In this work, we introduce a study of the user’s behaviour profile of a real bank institution by means of an explainable UEBA framework that combines AEs with Doc2Vec embeddings to process both numerical and textual features. Additionally, we provide a proof of equivalence between two common definitions of fully connected neural networks, grounding our design in universal approximation theory. Experiments on financial institution data and synthetic attack-derived anomalies show that the framework effectively detects threats and provides feature-level explanations of their origin. These results suggest that the proposed UEBA framework can be seamlessly integrated into enterprise environments.

Index Terms—Anomaly detection, User and Entity Behaviour Analytics, Autoencoders, Cyber Threat Detection

Type of Contribution: Extended summary. The full version of this paper was published in [1].

I. INTRODUCTION AND CONTRIBUTIONS

User and Entity Behaviour Analytics (UEBA) systems monitor deviations from habitual patterns across users, endpoints, and services [2]. In real enterprise settings, however, ground-truth attack labels are rare and existing controls often pre-filter only the most obvious incidents, leaving low-signal anomalies mixed into historical data. Unsupervised deep Autoencoders (AEs) are well suited for this setting, since they learn compact representations of normal behaviour, but tend to reconstruct atypical windows poorly, producing a reconstruction error that can be used as an anomaly score [3]. Moreover, AE residuals yield a simple, actionable source of explanation (which features fail to reconstruct) that helps analysts localise suspicious activity.

The paper makes two contributions:

- **Theory.** We prove that two widely used definitions of fully-connected feed-forward networks (composition of

affine maps and coordinate-wise activations vs. layered neuron graphs) are equivalent, connecting implementation practice with universal approximation results [4].

- **Method and system.** We propose an explainable UEBA pipeline that integrates Doc2Vec embeddings [5] with deep AEs to jointly model numerical features and textual process information, and demonstrate its operational integration on real enterprise telemetry.

II. A SUMMARY OF THE METHODOLOGY

Data and feature construction. Raw enterprise events (Windows security logs, email telemetry, antivirus and firewall alerts) are indexed in Splunk and aggregated into fixed-length time windows. For each window, we compute different behavioural variables capturing activity volume and timing: counts of new processes, successful/failed logins, security alerts, email statistics (sent/received counts, sizes, attachments, links), and PowerShell-related events.

Textual process representation. Many enterprise logs include semi-structured textual fields (e.g., executed process paths) that carry strong behavioural signal but are difficult to model with purely numeric approaches. We collapse the per-window list of executed processes into a single field and embed it using Doc2Vec (DBOW variant), obtaining a 64-dimensional vector that captures co-occurrence structure in process “tokens” [5]. This embedding is concatenated with the numerical variables, yielding an 83-dimensional feature vector per window.

Preprocessing. To preserve interpretability and avoid spurious spikes, missing activity is imputed conservatively: count variables are set to zero when no events occur; timing variables are set to the window duration when no timing events are observed; features are scaled with a robust scaler (to reduce outlier influence) followed by min–max normalisation.

Role-specific AEs and anomaly scoring. Because user roles differ substantially in baseline activity, we train separate models per group (Customer Management, CM; Executive Positions, EP). Each deep AE maps $\mathbb{R}^{83} \rightarrow \mathbb{R}^8 \rightarrow \mathbb{R}^{83}$ with hidden widths [64, 32, 16] (encoder), while the decoder follow a mirrored architecture. The model is trained to minimise an

L_1 reconstruction loss with Adam, L_1 regularisation and early stopping to prevent overfitting. The inference and anomaly scoring process follows Algorithm 1.

Algorithm 1: Inference and anomaly scoring

Input: New window $\mathcal{E}$; trained f_θ , ϕ , scaler; threshold

Output: Score s , residual vector r , decision

- 1) Extract features: $n = g_{\text{num}}(\mathcal{E})$, $t = \phi(\mathcal{T})$, $x = [n; t]$.
 - 2) Scale input: $\tilde{x} = \text{scale}(x)$.
 - 3) Reconstruct: $\hat{x} = f_\theta(\tilde{x})$.
 - 4) Compute residuals $r = \tilde{x} - \hat{x}$ and anomaly score $s = \|r\|_1$.
 - 5) Decision: $y = \mathbb{I}[s \geq \tau]$. Return (s, r, y) for alerting and visualisation.
-

Explainability and visual inspection. We use two complementary tools: (i) per-feature residuals $|x_j - \hat{x}_j|$ to highlight which behavioural dimensions drive an alert (e.g., login-related vs. email-related), and (ii) t-SNE projections [6] of both the original feature space and the residual space to assess separability and behavioural clustering.

III. EXPERIMENTAL EVALUATION

We analyse one year of enterprise telemetry for two groups: CM (25,313 windows) and EP (9,804 windows). Data are treated as unlabelled contaminated normal, reflecting realistic UEBA conditions. Using τ as threshold, the observed alert rates on the held-out test set remain close to the nominal 5% target (CM: 5.09%, EP: 4.61%), indicating that the models generalise and remain well calibrated despite role heterogeneity and the absence of ground truth labels.

A t-SNE analysis supports this interpretation: while the original feature space contains strong dependency clusters from routine behaviour, the residual space becomes more uniform, and flagged anomalies appear as scattered points.

To quantify detection sensitivity without extensive labels, we generate controlled anomalies from a set of real attack patterns (covering login, antivirus, email, and process-related anomalies). We construct synthetic samples by interpolating between normal windows and anomalous points using an intensity factor $\lambda \in [0, 1]$ (from weak to fully anomalous). Detection probability increases sharply with λ : across anomaly types, reliable detection typically emerges for $\lambda > 0.7$, while certain categories (login and antivirus anomalies) become detectable at much lower intensities (around $\lambda > 0.2$). Process anomalies require higher intensity, aligning with the added difficulty of representing rare sequences through Doc2Vec embeddings.

At last, the generated per-feature reconstruction errors provide actionable explanations: peaks concentrate on the features linked to the original anomaly type (e.g., email counters and attachment/link statistics for email anomalies; login and security-alert features for authentication-related anomalies).

Even when anomalies are complex (e.g., process-related), residual patterns are still able to guide the analysts toward the subset of behavioural dimensions related to the anomaly type.

IV. CONCLUSIONS AND FUTURE WORK

We introduce an explainable UEBA anomaly detection framework that combines numerical telemetry with textual process information via Doc2Vec embeddings and deep AEs. A supporting theoretical result establishes equivalence between two standard neural network formalisms, connecting implementation practice with universal approximation foundations. The framework remains calibrated on real enterprise logs without labels, detecting a broad set of attack-derived anomalies as intensity increases while producing feature-level residual explanations that facilitate analyst triage and root-cause investigation. The pipeline is designed for operational use, with model tracking and deployment components compatible with enterprise settings.

Key limitations include limited availability of labelled anomalies, potential information loss in Doc2Vec process embeddings, and restricted reproducibility due to private data. Future work includes to benchmark against additional baselines on public datasets, explore richer text encoders (such as transformer-based representations) for process and command-line fields, and integrate complementary explainability methods.

REFERENCES

- [1] J. Fuentes, I. Ortega-Fernandez, N. M. Villanueva, and M. Sestelo, “Cybersecurity threat detection based on a ueba framework using deep autoencoders,” *AIMS Mathematics*, vol. 10, no. 10, pp. 23496–23517, 2025.
- [2] M. Shashanka, M.-Y. Shen, and J. Wang, “User and entity behavior analytics for enterprise security,” in *Proc. IEEE Int. Conf. Big Data (Big Data 2016)*, pp. 1867–1874, 2016.
- [3] D. Rumelhart, G. Hinton, and R. Williams, “Learning internal representations by error propagation,” in *Parallel Distributed Processing: Explorations in the Microstructure of Cognition, Vol. 1: Foundations* (D. E. Rumelhart and J. L. McClelland, eds.), pp. 318–362, Cambridge, MA, USA: MIT Press, 1986.
- [4] M. Leshno, V. Y. Lin, A. Pinkus, and S. Schocken, “Multilayer feedforward networks with a nonpolynomial activation function can approximate any function,” *Neural Netw.*, vol. 6, no. 6, pp. 861–867, 1993.
- [5] Q. Le and T. Mikolov, “Distributed representations of sentences and documents,” in *Proc. 31st Int. Conf. Machine Learning (ICML 2014)*, vol. 32 of *Proc. Mach. Learn. Res.*, pp. 1188–1196, PMLR, 2014.
- [6] L. van der Maaten and G. Hinton, “Visualizing data using t-SNE,” *J. Mach. Learn. Res.*, vol. 9, pp. 2579–2605, 2008.

Caracterización de Ataques Imperceptibles en Vision-Language-Action Models

Asier Martínez de Guereñu, Xabier Sáez de Cámara, Irune Agirre
Ikerlan Technology Research Centre
Basque Research and Technology Alliance (BRTA)
Arrasate-Mondragón, Spain
{amartinezguerenu, xsaezdecamara, iagirre}@ikerlan.es

Pablo Valle, Aitor Arrieta
Mondragon Unibertsitatea
Arrasate-Mondragón, Spain
{pvalle, aarrieta}@mondragon.edu

Resumen—Los *Vision-Language-Action Models* (VLAs) integran percepción visual, lenguaje natural y control robótico, permitiendo ejecutar tareas físicas a partir de entradas multimodales. No obstante, esta integración amplía la superficie de ataque y plantea retos de robustez y seguridad. En este trabajo analizamos la sensibilidad de un VLA frente a perturbaciones sutiles aplicadas de forma unimodal en los canales lingüístico y visual. En el canal textual consideramos mutaciones de *prompts* basadas en caracteres Unicode invisibles y homoglifos. En el canal visual analizamos perturbaciones de baja magnitud, como *blur* local, variaciones suaves en *Hue*, *Saturation*, *Value* (HSV) y *pixel swaps*. La evaluación se realiza en simulación haciendo uso de un modelo típico del estado del arte, OpenVLA. Los resultados muestran que alteraciones de baja detectabilidad para un operador humano pueden degradar significativamente la ejecución (p. ej., detenciones inesperadas, oscilaciones y trayectorias erráticas), evidenciando una sensibilidad multimodal relevante en sistemas VLA orientados a control físico.

Index Terms—prompt perturbations, Unicode perturbations, multimodal robustness, robotic control, low-detectability perturbations, Vision-Language-Action Models

Tipo de contribución: *Investigación original*

I. INTRODUCCIÓN

Los *Vision-Language-Action Models* (VLAs) integran percepción visual, lenguaje natural y generación de acciones físicas, extendiendo el paradigma visión-lenguaje al control robótico [1], [2]. A diferencia de los *Vision-Language Models* (VLMs) tradicionales, en un VLA las entradas multimodales no solo soportan comprensión, sino que condicionan directamente la política de control del robot. Esto los convierte en componentes especialmente relevantes en sistemas ciberfísicos, donde pequeñas desviaciones en la interpretación de la entrada pueden trasladarse al dominio físico.

La robustez de los VLMs frente a perturbaciones adversarias ha sido ampliamente estudiada [3], pero en VLAs esta cuestión sigue menos explorada. Trabajos recientes como EvalVLA y VLATest han mostrado sensibilidad a variaciones físicas del entorno, ruido sensorial y condiciones de evaluación realistas [4], [5]. Sin embargo, sigue existiendo un vacío en torno a perturbaciones de *baja detectabilidad* en los canales de texto e imagen que, aun sin alterar de forma evidente la entrada para un operador humano, puedan degradar la ejecución robótica.

En este trabajo estudiamos ese escenario concreto. Nos centramos en perturbaciones *no adaptativas* y *black-box*, es decir, no consideramos ataques optimizados por gradiente ni manipulaciones semánticas complejas del *prompt*, sino mutaciones plausibles de baja magnitud orientadas a caracterizar

la sensibilidad operativa del sistema. En el canal lingüístico analizamos inserciones de caracteres Unicode invisibles, sustitución de espacios por variantes Unicode y reemplazos mediante homoglifos [6], [7]. En el canal visual consideramos *blur* local ligero, variaciones suaves en HSV y *pixel swaps* locales [8], [9], [10]. Aunque estas transformaciones no constituyen ataques adversarios optimizados en sentido estricto, sí representan un escenario realista para analizar la exposición de los VLAs a entradas sutilmente alteradas. En consecuencia, la contribución principal de este trabajo no es proponer un nuevo mecanismo de generación adversaria, sino caracterizar experimentalmente cómo perturbaciones sutiles en texto e imagen pueden trasladarse al dominio del control físico en un VLA.

La evaluación se realiza en simulación sobre OpenVLA [2], utilizando tres instrucciones representativas de tareas *Pick and Place* derivadas de VLATest [5]. Además de la tasa de éxito, analizamos métricas dinámicas de estabilidad que permiten capturar degradaciones continuas en la calidad del control, incluso cuando la tarea llega a completarse. Este punto es especialmente importante en robótica: una perturbación puede no cambiar el resultado binario final y, aun así, inducir trayectorias más erráticas, oscilaciones o movimientos menos precisos.

A partir de este planteamiento formulamos dos preguntas de investigación: **RQ1**) ¿hasta qué punto mutaciones del *prompt* de baja detectabilidad afectan a la ejecución física de un VLA?, y **RQ2**) ¿en qué medida perturbaciones visuales ligeras degradan su comportamiento? Nuestro objetivo no es demostrar la vulnerabilidad del modelo frente a atacantes adaptativos, sino ofrecer una caracterización preliminar de cómo pequeñas alteraciones textuales y visuales pueden trasladarse al dominio del control físico.

En resumen, este trabajo realiza tres aportaciones: (i) caracteriza perturbaciones lingüísticas basadas en Unicode invisible y homoglifos, (ii) estudia perturbaciones visuales locales de baja magnitud, y (iii) evalúa su impacto sobre OpenVLA mediante métricas de éxito y estabilidad. Los resultados se limitan a un único modelo, tres instrucciones y simulación, por lo que deben interpretarse como evidencia exploratoria, pero permiten delimitar un escenario de sensibilidad multimodal relevante para futuras evaluaciones de robustez en VLAs.

II. ESCENARIO EXPERIMENTAL

En esta sección se describe el entorno experimental utilizado para analizar el impacto de perturbaciones multimodales de

baja detectabilidad (texto e imagen) sobre el comportamiento de modelos VLA .

II-A. Dataset y tarea

La evaluación se realiza sobre la tarea *Pick and Place* del dataset Fractal, empleando un conjunto de instrucciones lingüísticas (i.e., *prompts*) previamente utilizadas en VLA-Test [5] y en trabajos posteriores [11].

En este contexto, la tarea define el objetivo genérico de manipulación (recoger y colocar un objeto), mientras que las instrucciones especifican instancias concretas de dicha tarea en distintos entornos y configuraciones iniciales. Esta diferenciación permite analizar de forma sistemática el efecto de perturbaciones sutiles sobre el *prompt* o la entrada visual, manteniendo constante la estructura general de la tarea.

Cada ejecución se define por una secuencia de frames del entorno simulado, una instrucción textual y el estado del agente, lo que permite evaluar de manera controlada la degradación del comportamiento inducida por las perturbaciones.

II-B. Modelo VLA

Como modelo bajo estudio se emplea OpenVLA [2] en su versión 7B, un VLA orientado a tareas de manipulación robótica que genera acciones a partir de observaciones visuales y una instrucción en lenguaje natural. Su uso se justifica tanto por su amplia adopción como por su idoneidad para analizar degradaciones de comportamiento inducidas por perturbaciones multimodales de baja detectabilidad.

II-C. Simulador

Los experimentos se ejecutan en ManiSkill2, utilizando el entorno SimplifierEnv [12]. La simulación permite realizar evaluaciones controladas y reproducibles, facilitando la instrumentación del estado del agente y el registro de trayectorias sin los riesgos asociados a hardware real. Esta configuración resulta clave para detectar fallos de tarea, desviaciones de trayectoria o comportamientos anómalos como inmovilidad.

II-D. Metodología experimental

Evaluamos la sensibilidad de OpenVLA frente a perturbaciones *no adaptativas* y de baja detectabilidad en los canales lingüístico y visual durante la ejecución robótica en simulación. Partimos de aproximadamente 500 instrucciones de VLATest [5] y realizamos un filtrado previo para seleccionar únicamente aquellas con comportamiento determinista: cada *prompt* candidato se ejecuta 15 veces sin perturbaciones y se conserva solo si alcanza una tasa de éxito del 100 %. Tras este proceso se obtienen 35 instrucciones estables, de las que se seleccionan tres representativas para los experimentos: *pick apple*, *pick blue plastic bottle* y *pick pepsi can*.

En el canal lingüístico, dado un *prompt* original p , generamos una variante p' mediante mutaciones estocásticas que preservan aproximadamente su apariencia, pero alteran su codificación Unicode o tokenización: (i) inserción de $\text{U}+200\text{C}$, (ii) sustitución de espacios ASCII por $\text{U}+2800$, y (iii) reemplazo de caracteres latinos por homógrafos visualmente equivalentes. En el canal visual, aplicamos perturbaciones locales sobre la imagen de entrada mediante una máscara discreta $M \in \{0, 1, 2, 3\}^{H \times W}$, donde cada valor indica (i) ausencia de cambio, (ii) *blur* local 3×3 , (iii) variación suave

del canal *Value* en HSV, o (iv) *pixel swap* horizontal. En ambos casos se emplea un esquema progresivo de intensidad con cuatro niveles (5 %, 10 %, 15 % y 20 %), generando 25 instancias independientes por nivel. Como proxy de magnitud, la perturbación textual se cuantifica mediante la distancia normalizada de Levenshtein entre p y p' , mientras que la visual se mide como porcentaje de píxeles modificados.

El protocolo consta de tres escenarios: **solo texto**, **solo visión** y **texto+visión**. Para cada escenario se ejecuta primero una condición *baseline* sin perturbaciones, repetida 5 veces, y posteriormente 100 ejecuciones mutadas (25 por nivel de intensidad), repitiendo cada una 5 veces y promediando las métricas. Se evalúan tanto el **Success Rate** (SR) como métricas continuas de comportamiento: **Optimal Trajectory** (OT), **Trajectory Instability** (TI), **Velocity Instability** (VI) y **TCP Position Instability** (PI). Para las métricas continuas, las secuencias temporales se comparan con el *baseline* mediante *Dynamic Time Warping* (DTW), lo que permite capturar degradaciones en estabilidad y calidad de control incluso cuando la tarea llega a completarse. En consecuencia, el estudio no pretende modelar ataques adversarios optimizados ni evaluar la robustez frente a atacantes adaptativos, sino caracterizar de forma preliminar cómo perturbaciones de baja detectabilidad en texto e imagen afectan a la ejecución robótica y a la estabilidad del control.

II-E. Limitaciones del estudio

La evaluación se limita a un único modelo (OpenVLA), tres instrucciones y simulación, por lo que no pretende generalizar a todos los VLAs ni a entornos físicos reales. Además, el estudio considera perturbaciones *no adaptativas* en un escenario *black-box*, y la baja detectabilidad se aproxima mediante proxies como la distancia de Levenshtein o el porcentaje de píxeles alterados, sin validación perceptual humana explícita. En este sentido, el trabajo debe entenderse como una caracterización preliminar de sensibilidad multimodal.

III. RESULTADOS Y DISCUSIÓN

Esta sección presenta los resultados obtenidos al aplicar perturbaciones de baja detectabilidad en los canales lingüístico y visual sobre OpenVLA. El análisis se realiza siempre respecto al *baseline* sin perturbaciones (ejecución 0), donde la tasa de éxito es del 100 % (5/5 repeticiones exitosas) y las métricas dinámicas muestran distribuciones compactas y baja variabilidad. Esto confirma que las desviaciones observadas bajo perturbación no responden a inestabilidad estructural del simulador, sino al efecto de las alteraciones introducidas.

Además del *Success Rate* (SR) agregado (Tabla I), analizamos las distribuciones de las métricas dinámicas OT-PI (Figura 1), ya que en robótica el fallo no siempre se manifiesta como un colapso binario de la tarea, sino también como pérdida de suavidad, precisión o consistencia en la ejecución.

III-A. Perturbaciones textuales

Las mutaciones del *prompt* producen la degradación más severa. A medida que aumenta la intensidad, las distribuciones de OT, TI y VI se expanden progresivamente, lo que indica pérdida de alineación con la trayectoria nominal y un régimen de control menos estable. Esta degradación no se limita al resultado final: incluso en ejecuciones exitosas, el

comportamiento aparece más disperso y menos consistente entre repeticiones nominalmente idénticas.

En términos de *SR*, el escenario *solo prompt* cae del 100 % al 23 % total (Tabla I), con una reducción especialmente marcada a intensidades altas. Este resultado sugiere que pequeñas alteraciones en codificación o tokenización pueden modificar de forma persistente la política de acción generada por el modelo. En consecuencia, el canal lingüístico no actúa únicamente como especificación inicial de la tarea, sino como modulador estructural del comportamiento de control.

III-B. Perturbaciones visuales

Las perturbaciones visuales muestran un patrón diferente. Aunque el *SR* total desciende al 31 %, la degradación aparece sobre todo en las métricas dinámicas, especialmente VI y PI, donde se observa mayor oscilación y menor suavidad en la ejecución. Esto apunta a un efecto más localizado sobre la estabilidad cinemática que sobre la viabilidad binaria de la tarea.

La diferencia respecto al canal textual es relevante: el escenario visual mantiene una tasa de éxito 8 puntos superior al textual (31 % frente a 23 %), pero lo hace con trayectorias menos consistentes. Dicho de otro modo, el sistema puede seguir completando la tarea, aunque con peor calidad de control. En un entorno físico real, esta pérdida de estabilidad podría amplificarse por fricción, latencias o incertidumbre mecánica, por lo que evaluar robustez únicamente mediante éxito/fallo podría subestimar degradaciones funcionales importantes.

III-C. Perturbaciones combinadas

La combinación de perturbaciones textuales y visuales no muestra un efecto multiplicativo claro. El escenario *prompt+visual* alcanza un *SR* total del 21 %, muy próximo al caso de *solo prompt* (23 %) y por debajo del escenario exclusivamente visual (31 %). De forma coherente, las distribuciones de estabilidad en la Figura 1 reproducen esencialmente el patrón del modo textual, lo que sugiere una dominancia del canal lingüístico sobre la degradación global de la tarea.

Esta asimetría también se aprecia en la evolución temporal de *Velocity Instability* (Figura 2), donde el modo textual muestra desviaciones más persistentes respecto al *baseline*, mientras que el modo visual presenta picos más localizados.

III-D. Interpretación global

En conjunto, los resultados sugieren que la sensibilidad multimodal de OpenVLA no es simétrica. Las perturbaciones textuales parecen afectar a la configuración global de la política latente, mientras que las visuales impactan principalmente en la ejecución continua. Esta lectura es consistente con una estructura jerárquica implícita del control: el lenguaje condiciona la planificación de alto nivel y la visión ajusta la ejecución a nivel local.

Desde la perspectiva de sistemas ciberfísicos, esta distinción es relevante. Incrementos en la variabilidad dinámica, incluso sin fallo explícito de tarea, pueden traducirse en riesgos operativos cuando el robot interactúa con personas u objetos frágiles. En consecuencia, la robustez de los VLAs no debería evaluarse únicamente con métricas binarias de éxito, sino también con indicadores de estabilidad que capten degradaciones cinemáticas sutiles pero potencialmente críticas.

Tabla I: Resumen del *SR* por bloques de intensidad (100 ejecuciones).

Escenario	5 %	10 %	15 %	20 %	Total
Solo Prompt	40 %	36 %	12 %	4 %	23 %
Solo Visual	16 %	44 %	28 %	36 %	31 %
Prompt + Visual	28 %	32 %	16 %	8 %	21 %

IV. CONCLUSIONES Y LÍNEAS FUTURAS

Este trabajo presenta un análisis preliminar del impacto de perturbaciones de baja detectabilidad en los canales lingüístico y visual sobre el comportamiento de un modelo VLA. A partir de métricas de estabilidad y del *Success Rate* (*SR*), los resultados muestran que pequeñas alteraciones en la entrada pueden degradar de forma significativa la ejecución robótica.

El escenario *baseline* sin perturbaciones permite contextualizar cuantitativamente estas desviaciones. En conjunto, los resultados indican que la similitud perceptiva no garantiza estabilidad: las mutaciones del *prompt* producen degradaciones más estructurales, mientras que las perturbaciones visuales afectan principalmente a la calidad cinemática del control. Esta asimetría sugiere que el canal lingüístico actúa como modulador de alto nivel de la política de acción. En consecuencia, la robustez de los VLAs no debería evaluarse solo con métricas perceptivas o tasas binarias de éxito, sino también mediante indicadores de estabilidad del comportamiento físico. Asimismo, estos resultados sugieren la conveniencia de estudiar mecanismos de defensa específicos, especialmente en el canal lingüístico.

Como trabajo futuro, se propone extender el análisis a más modelos VLA y a un conjunto más amplio de tareas, así como estudiar perturbaciones adaptativas y validar los resultados en entornos físicos reales. También resulta relevante explorar mecanismos de defensa como normalización robusta de entradas, detección de anomalías Unicode o entrenamiento adversarial multimodal.

REFERENCIAS

- [1] A. Brohan, N. Brown, and J. e. a. Carbajal, "RT-1: Robotics Transformer for Real-World Control at Scale," 8 2023. [Online]. Available: <http://arxiv.org/abs/2212.06817>
- [2] M. Jin Kim, K. Pertsch, and S. e. a. Karamcheti, "OpenVLA: An Open-Source Vision-Language-Action Model OpenVLA Closed-Loop Robot Control Policy," 2024. [Online]. Available: <https://openvla.github.io>
- [3] Z. Yin, M. Ye, and T. e. a. Zhang, "VLATTACK: Multimodal Adversarial Attacks on Vision-Language Tasks via Pre-trained Models," *Advances in Neural Information Processing Systems*, vol. 36, 10 2023. [Online]. Available: <https://arxiv.org/pdf/2310.04655>
- [4] H. Liu, J. Long, and J. e. a. Wu, "Eva-VLA: Evaluating Vision-Language-Action Models' Robustness Under Real-World Physical Variations," 9 2025. [Online]. Available: <https://arxiv.org/pdf/2509.18953>
- [5] Z. Wang, Z. Zhou, and J. e. a. Song, "VLATest: Testing and Evaluating Vision-Language-Action Models for Robotic Manipulation," *Proceedings of the ACM on Software Engineering*, vol. 2, no. FSE, pp. 1615–1638, 6 2025. [Online]. Available: <https://doi/pdf/10.1145/3729343?download=true>
- [6] A. Dionysiou and E. Athanasopoulos, "Unicode Evil: Evading NLP Systems Using Visual Similarities of Text Characters," *AISec 2021 - Proceedings of the 14th ACM Workshop on Artificial Intelligence and Security, co-located with CCS 2021*, vol. 12, no. 21, pp. 111–122, 11 2021. [Online]. Available: <https://doi/pdf/10.1145/3474369.3486871?download=true>
- [7] N. Boucher, I. Shumailov, R. Anderson, and N. Papernot, "Bad Characters: Imperceptible NLP Attacks," *Proceedings - IEEE Symposium on Security and Privacy*, vol. 2022-May, pp. 1987–2004, 6 2021. [Online]. Available: <https://arxiv.org/pdf/2106.09898>




Figura 1: Distribución de métricas de estabilidad bajo perturbaciones combinadas del *prompt* y del canal visual.




Figura 2: Evolución temporal de *Velocity Instability* (VI) en tres dimensiones articulares para cuatro niveles representativos de intensidad. Se comparan los tres modos (solo texto, solo imagen y texto+imagen) frente al *baseline*.

- [8] Y. Qin, N. Carlini, and I. e. a. Goodfellow, “Imperceptible, Robust, and Targeted Adversarial Examples for Automatic Speech Recognition,” *36th International Conference on Machine Learning, ICML 2019*, vol. 2019-June, pp. 9141–9150, 3 2019. [Online]. Available: <https://arxiv.org/pdf/1903.10346>
- [9] Z. Zhao, Z. Liu, and M. Larson, “Towards Large yet Imperceptible Adversarial Image Perturbations with Perceptual Color Distance,” *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp. 1036–1045, 11 2019. [Online]. Available: <https://arxiv.org/pdf/1911.02466>
- [10] N. Carlini and D. Wagner, “Towards Evaluating the Robustness of Neural Networks,” *Proceedings - IEEE Symposium on Security and Privacy*, pp. 39–57, 8 2016. [Online]. Available: <https://arxiv.org/pdf/1608.04644>
- [11] P. Valle, C. Lu, S. Ali, and A. Arrieta, “Evaluating Uncertainty and Quality of Visual Language Action-enabled Robots,” *arXiv preprint arXiv:2507.17049*, 7 2025. [Online]. Available: <http://arxiv.org/abs/2507.17049>
- [12] “simpler-env/ManiSkill2_real2sim: SAPIEN ManiSkill2 environments for Real2Sim manipulation policy evaluation.” [Online]. Available: https://github.com/simpler-env/ManiSkill2_real2sim

A Review of: “Automated Moving Target Defence in OT Security: Dynamic IP-enabled VLAN and Port Shuffling.”

Valentine Machaka^{1,2}
vmachaka@ceit.es

Saioa Arrizabalaga^{1,2}
sarrizabalaga@ceit.es

Josune Hernantes²
jhernantes@unav.es

¹CEIT-Basque Research and Technology Alliance (BRTA), Manuel Lardizabal 15, 20018 Donostia / San Sebastián, Spain.

²Universidad de Navarra, Tecnun, Manuel Lardizabal 13, 20018 Donostia / San Sebastián, Spain.

Resumen—Operational Technology (OT) environments have conventionally relied on legacy systems with static Internet Protocol (IP) addressing and often lack security features. This poses challenges to integrating dynamism, which is essential for security and resilience. The proposed solution is an Automated Moving Target Defence (AMTD) that leverages OpenFlow and NetConf/YANG models within Software-Defined Networking (SDN). Referring to the Open Systems Interconnection (OSI) network model, this innovative approach introduces the shuffling of Layer 2 IEEE 802.1Q Virtual Local Area Networks (VLANs), Layer 3 IP-enabled VLAN Interfaces, and Layer 4 Transport Control Protocol (TCP) Ports to disrupt an attacker’s ability to understand, map, and persist within the network. An experimental virtualised cyber-physical system (CPS) testbed has been developed to demonstrate the practicality of the AMTD shuffling method and to closely align with real-world scenarios. The study evaluates the AMTD method’s impact on system performance and underscores its potential contributions to enhancing OT cybersecurity while preserving critical processes. This research uses an industrial case study of a simulated virtual wastewater treatment plant communicating over the Open Platform Communications Unified Architecture (OPC-UA) protocol.

Index Terms—Network Programming, CPS Testbeds, Software-Defined Networking, Dynamic IP Shuffling, Moving Target Defence (MTD), Cybersecurity

Tipo de contribución: *Research already published [1].*

I. INTRODUCTION

CYBER-PHYSICAL systems (CPS) in critical infrastructure rely on static IP addressing and legacy devices, creating predictable attack surfaces vulnerable to reconnaissance and unauthorised access. Traditional static defences such as firewalls and intrusion detection and/or prevention systems (IDS/IPS) can be circumvented through prolonged reconnaissance.

Automated Moving Target Defence (AMTD) addresses these limitations by dynamically reconfiguring network parameters to create an unpredictable attack surface, disrupting adversarial mapping, persistence, and targeted exploits. This approach aligns with IEC 62443-3-3 compensatory security measures, providing an additional defence layer for legacy OT environments.

Originating from military tactics and gaining prominence through Defence Advanced Research Projects Agency (DARPA) [2] initiatives in the early 2000s, AMTD now encompasses diverse techniques, including address randomisation, network topology reconfiguration, instruction set randomisation, and software diversity.

This work presents an AMTD approach that exposes decoy infrastructure by continuously reshuffling the attack surface through real-time dynamic reassignment of VLANs, IP-enabled VLANs, and ports, maintaining operational integrity while disrupting reconnaissance patterns.

II. STATE-OF-THE-ART

Existing SDN-based AMTD work is largely limited to flat, single-switch topologies—approximately 70 % using Mininet or MiniCPS simulations—or to DHCP-based IP management, which is incompatible with OT static-address requirements (30 %). Critically, these confine randomisation to a single segment rather than across a hierarchical, multi-tier path. This work addresses both gaps through a physical, hierarchical CPS testbed spanning the core, distribution, and access layers, with heterogeneous switch categories, introducing shuffled paths across tiers and exposing decoy infrastructure via real-time reassignment of VLANs, IP-enabled VLANs, and ports, while preserving operational integrity.




Figura 1. CPS Testbed: Dynamic IP-enabled VLAN and Port Shuffling.

III. PROPOSED SOLUTION

The proposed CPS testbed (Figure 1) implements a hierarchical network architecture with NetConf-configurable access and distribution switches (Categories A and C), Simulink Docker container running the WWTP model and OPC UA blocks, dynamic shuffling, and a centralised SDN controller with DNS integration. The AMTD mechanism continuously shuffles VLAN IDs, IP-enabled VLAN interfaces, trunk ports,

and TCP ports at predefined intervals (e.g., every 15 seconds), creating a bidirectional mapping where real IP-port pairs correspond to rotating sets of virtual IP-port pairs. Clients communicate through DNS-resolved virtual addresses that remain transparent during sessions, while the underlying real addresses stay hidden.

The testbed was implemented in GNS3 using RYU (OpenFlow controller) and NetClient (NetConf automation), with a MATLAB Simulink Docker container running the WWTP model and OPC-UA blocks enabling real-time communication between the virtual PLC and HMI. Security validation employs the MITRE ATT&CK ICS framework¹, targeting Network Sniffing (T0842), Network Service Scanning (T0840), and Denial of Service (T0814) via Nmap, Ettercap, and the OPC-UA Exploit Framework. Performance is assessed through one-way latency and cycle time against IEC 62541 thresholds.

IV. RESULTS

The proposed solution achieves a one-way latency of ~ 6 ms and cycle time of 14.582ms, within the 1–100ms range of IEC 62541 for OPC-UA and the 10–16ms ICS threshold [3]. Security validation confirmed full disruption of reconnaissance (T0840), MiTM (T0842), and DoS (T0814) attacks: decoy infrastructure misdirected adversaries, obfuscated traffic prevented interception, and dynamic reshuffling across network tiers broke attack persistence. Unlike simulation-based prior art confined to single-segment randomisation, the physical multi-tier testbed demonstrates robust protection without modifying legacy devices. Performance remained consistent across five test cycles with shuffling intervals of 20, 40, and 60 seconds, indicating stable and repeatable behaviour.

Tabla I
PERFORMANCE AND SECURITY EVALUATION SUMMARY.

Performance Metrics.				
Metric	NO AMTD	AMTD		
One-way Latency (ms)	~2	~6		
Avg Cycle Time (ms)	3.353	14.582		
Excellent (< 10ms)	85.1 %	4.8 %		
Good (10–99ms)	14.9 %	95.2 %		
Poor/Very Bad	0.0 %	0.04 %		
Security Evaluation (MITRE ATT&CK ICS.)				
Attack Technique	NO AMTD	AMTD		
OT Network Scanning (T0840)	Success: 7 hosts in 1.89s, Port 4840 exposed	Failed: only, filtered	Decoys ports	
MiTM/Sniffing (T0842)	Success: Data exposed	Failed: Obfuscated		
DoS (T0814)	Attack executed	Failed: No persistence		

V. DISCUSSIONS

AMTD pays off most when reconnaissance time is the critical threat vector and OPC UA latency can tolerate 10 ms overhead. Performance measurements (Table I) demonstrate that AMTD introduces measurable but acceptable overhead. Without AMTD, 85.1 % of communications achieve excellent

performance (< 10 ms). With AMTD enabled, average cycle time rises to 14.582ms, shifting 95.2 % of communications to the good category (10–99ms). While peak performance degrades, these values remain within acceptable thresholds for most ICS applications. These results are comparable to related works, though multi-tier architectures inherently trade some performance for stronger security segmentation aligned with IEC 62443-3-3 principles.

The shuffle interval controls the frequency of attacker disruption; per-transition overhead remains constant regardless of the interval. Decoy VLAN count and DNS TTL alignment are secondary factors that affect the depth of reconnaissance confusion and session continuity, respectively. The approach is best suited to hierarchical OT networks where external reconnaissance is the primary threat. Environments with hard real-time constraints below 5ms, unvalidated multi-client topologies, or DNS as an attack surface should evaluate these factors before deployment.

Unlike simulation-based approaches, the physical testbed better represents real-world constraints and demonstrates that VLAN-as-decoy functionality with multi-tier shuffling provides robust protection without modifying legacy devices. Key improvement priorities include multi-client scalability and reducing computational load during IP transitions.

VI. CONCLUSION

This research demonstrates the feasibility of dynamic IP-enabled VLAN and TCP port shuffling across a hierarchical OT network by integrating NetConf automation with OpenFlow programming to enable multi-tier path shuffling without modifying legacy devices. With a one-way latency of ~ 6 ms and cycle time of ~ 14.5 ms, the approach meets IEC 62541 thresholds while systematically defeating reconnaissance, MiTM, and DoS attacks. It is most impactful where external reconnaissance is the primary threat vector. Much like a general who loses the battle before it begins by allowing the enemy to study their terrain and supply lines, an OT network that permits unchecked reconnaissance has already conceded the most critical advantage. Future work targets machine-learning-driven adaptive mechanisms and validation of multi-client scalability. Future work includes comparative analysis of alternative AMTD approaches and extended defence strategies incorporating machine learning-driven adaptive mechanisms for critical infrastructure.

REFERENCIAS

- [1] V. Machaka, S. Arrizabalaga, and J. Hernantes, “Automated moving target defence in ot security: Dynamic ip-enabled vlan and port shuffling,” in *2025 3rd International Conference on Artificial Intelligence and Automation Control (AIAC)*, 2025, pp. 98–105.
- [2] R. E. Navas, F. Cuppens, N. Boulahia Cuppens, L. Toutain, and G. Z. Papadopoulos, “Mtd, where art thou? a systematic review of moving target defense techniques for iot,” *IEEE Internet of Things Journal*, vol. 8, no. 10, pp. 7818–7832, 2021.
- [3] F. Holik, *Meeting Smart City Latency Demands with SDN*. Cham: Springer International Publishing, 2020, pp. 43–54. [Online]. Available: https://doi.org/10.1007/978-3-030-14132-5_4

¹MITRE ATT&CK ICS: <https://attack.mitre.org/matrices/ics/>

Metodología para la caracterización y modelado de la propagación de riesgos de ciberseguridad

Mario Gutiérrez Delgado¹, Carmen Sánchez-Zas^{1 2}, Sonia Solera-Cotanilla^{1 2},
Xavier Larriva-Novo^{1 2}, Víctor A. Villagrà^{1 2}

¹ Universidad Politécnica de Madrid (UPM). DIT, ETSI Telecomunicaciones. Avda. Complutense 30, 28040 Madrid

² Information Processing and Telecommunications Center. Universidad Politécnica de Madrid

ETSI Telecomunicación. Avda. Complutense 30, Madrid 28040, España

mario.gutierrezd@alumnos.upm.es, carmen.szas@upm.es, sonia.solera@upm.es,

xavier.larriva.novo@upm.es, victor.villagra@upm.es

Resumen—La creciente interconectividad de los sistemas digitales ha incrementado la complejidad y el alcance de los riesgos de ciberseguridad, favoreciendo su propagación a través de infraestructuras y organizaciones interdependientes. Esta propuesta analiza la propagación de los riesgos de ciberseguridad desde la llegada de una amenaza a un sistema, evaluando las relaciones entre activos y modelando un conjunto de reglas de propagación. Se propone un sistema que permite modelar los mecanismos de transmisión del riesgo y capturar efectos en cascada derivados de dependencias entre activos y su relevancia dentro del marco de riesgos de ciberseguridad. Este enfoque dinámico facilita la identificación de puntos críticos y la evaluación de escenarios.

Index Terms—Propagación de riesgo, Gestión de riesgo, ITSRM, Ciberseguridad

Tipo de contribución: *Investigación original*

I. INTRODUCCIÓN

La transformación digital y la creciente interconectividad de infraestructuras críticas, servicios en la nube y dispositivos IoT han expandido la superficie de ataque y la complejidad de los entornos actuales [1]. En este escenario, la ciberseguridad es fundamental para garantizar la resiliencia y la continuidad operativa [2].

Si bien los marcos metodológicos utilizados permiten identificar y evaluar amenazas, suelen ofrecer una visión estática del riesgo. Generalmente, evalúan escenarios puntuales sin capturar la evolución temporal ni los efectos en cascada derivados de las interdependencias entre activos [3], lo que genera la necesidad de modelos de análisis dinámico que consideren las relaciones de dependencia y las reglas de transmisión de impacto.

Este trabajo propone un sistema para el modelado de la propagación de riesgos de ciberseguridad basado en la definición de relaciones entre activos y la aplicación de reglas de propagación. El enfoque permite representar mecanismos de transmisión, identificar puntos críticos y evaluar escenarios de ataque, facilitando la toma de decisiones en entornos complejos.

El documento se estructura de la siguiente manera: la Sección II presenta el marco teórico; la Sección III detalla la metodología de propagación propuesta; la Sección IV expone la validación mediante un caso de uso; y, finalmente, la Sección V resume los resultados y líneas de trabajo futuro.

II. MARCO TEÓRICO

II-A. Gestión de riesgos

La gestión de riesgos es el proceso iterativo de identificar, evaluar, mitigar y monitorizar amenazas para minimizar su impacto en la organización [4]. En el ámbito de las TI, el riesgo surge cuando una amenaza explota la vulnerabilidad de un activo, requiriendo contramedidas para su tratamiento (transferir, evitar, aceptar o mitigar) [5]. Este trabajo optimiza las fases de identificación y evaluación al transformar el análisis estático tradicional en un modelo dinámico basado en interdependencias utilizando metodologías como IT Security Risk Management (ITSRM) [6].

II-A1. Propagación de riesgos: La propagación de riesgos [7] analiza cómo la materialización de una amenaza en un activo genera un efecto cascada sobre nodos interconectados. En lugar de un desplazamiento lineal, este enfoque considera cómo las dependencias del sistema facilitan que una amenaza local escale su criticidad al trascender su origen. Integrar este mecanismo permite identificar puntos críticos ocultos y obtener una visión precisa de la resiliencia del sistema ante incidentes complejos.

III. DESARROLLO

La metodología propuesta permite una gestión dinámica del riesgo al considerar cómo el compromiso de un activo puede afectar a otros elementos interconectados dentro del sistema. Parte del principio de que los activos no operan de forma aislada, sino que forman una red de dependencias funcionales en la que la materialización de una amenaza en un nodo puede desencadenar efectos en cascada. Para modelar esta propagación, el sistema se basa en un conjunto de catálogos y datos de entrada que estructuran tanto la caracterización del entorno como las reglas de transmisión del riesgo.

En primer lugar, se definen los activos, cada uno con un valor de importancia que refleja su relevancia técnica y estratégica. A ellos se asocian las amenazas, obtenidas de sistemas de monitorización y responsables de activar el proceso de análisis. Los eventos temidos representan las consecuencias críticas identificadas por expertos, determinando el impacto asociado a cada riesgo potencial. El catálogo de relaciones describe los vínculos entre activos, indicando su dirección y un valor de criticidad que determina la relevancia de la dependencia. Finalmente, el catálogo de escenarios

de amenaza establece si una amenaza concreta sobre un activo puede desencadenar un evento temido, así como la probabilidad de su materialización. Todos estos elementos se complementan con el catálogo de reglas de propagación, que constituye el motor lógico del modelo y determina bajo qué condiciones un evento temido puede generar nuevas amenazas sobre activos relacionados.

El proceso de evaluación se inicia cuando el sistema detecta una amenaza sobre un activo. A partir de ella, se comprueba si existe un escenario de amenaza asociado; de ser así, se materializa un evento temido que origina un riesgo potencial. Su nivel se calcula a partir del producto entre la probabilidad asignada al escenario y el impacto definido en el catálogo de eventos temidos, siguiendo la *Ec. (1)*.

$$\text{Riesgo potencial} = \text{Probabilidad} \times \text{Impacto} \quad (1)$$

El riesgo inicial calculado para un activo, junto con la información sobre sus relaciones y las reglas de propagación, permite determinar si el evento temido puede extenderse a otros elementos del sistema. La metodología asume que los activos forman parte de una red de dependencias funcionales y que la materialización de una amenaza en uno de ellos puede desencadenar efectos en cascada, alterando la criticidad del sistema de forma dinámica.

La propagación comienza cuando una amenaza detectada sobre un activo genera un evento temido. A partir de este punto, el sistema consulta el catálogo de reglas de propagación para comprobar si dicho evento tiene alguna regla asociada. Cada regla establece las condiciones bajo las cuales un evento temido puede originar una nueva amenaza en activos relacionados, considerando siempre un valor mínimo de criticidad en la relación que valide dicha transmisión. Para ello, el catálogo define tres elementos clave: el evento temido que actúa como desencadenante, la amenaza resultante que se generaría en el activo destino y la criticidad mínima exigida para que la propagación sea válida.

Identificada una regla aplicable, el sistema analiza las relaciones del activo afectado basándose en el catálogo de relaciones, evaluando si la criticidad del vínculo con otro activo es igual o superior a la establecida por la regla correspondiente. Cuando se cumple esta condición, se genera una nueva amenaza en el activo destino. A continuación, se consulta el catálogo de escenarios de amenaza para comprobar si esa nueva amenaza puede materializarse en un evento temido. En caso afirmativo, el proceso continúa evaluando las relaciones del nuevo activo afectado y determinando posibles propagaciones adicionales.

Para evitar recurrencias o ciclos infinitos, el sistema registra cada par amenaza-activo generado, de modo que ninguna combinación ya evaluada pueda volver a procesarse. La propagación se detiene cuando no existen reglas aplicables, no se cumplen las condiciones de criticidad o la amenaza generada no tiene un escenario asociado que desencadene un nuevo evento temido. Este proceso permite capturar la evolución dinámica del riesgo en sistemas distribuidos, reflejando cómo una amenaza inicial puede escalar y afectar a múltiples componentes a través de dependencias críticas.

De forma equivalente a los eventos temidos originales, aquellos generados mediante el proceso de propagación lle-

van asociado un riesgo potencial propagado. Sus valores de impacto y probabilidad se determinan siguiendo el mismo procedimiento empleado para el riesgo potencial original, siendo el cálculo de dicho riesgo también idéntico (*Ec. (1)*). Tras la obtención de todos los riesgos presentes (originales y potenciales), el riesgo final de cada activo se establece como el valor máximo de los riesgos que le afectan, integrando tanto las amenazas originales como las propagadas (*Ec. (2)*).

$$\text{Riesgo}_{\text{activo}} = \max_{i=1,\dots,n} \{r_i\} \quad (2)$$

Donde r_i hace referencia a los riesgos potenciales que afectan al activo y n es la cantidad total de riesgos que le afectan.

Finalmente, tras evaluar el riesgo de cada uno de los activos, se calculan los indicadores de riesgo del sistema completo. En este punto, es necesario conocer el riesgo relativo de cada uno de los eventos temidos, teniendo en cuenta los valores de importancia de los activos a los que afectan en el sistema. Para ello, se utiliza la *Ec. (3)*.

$$\text{Riesgo relativo} = \lceil \text{Riesgo potencial} \times \text{Importancia} \rceil \quad (3)$$

Este cálculo pondera la criticidad del riesgo en relación con el sistema, basándose en la importancia del activo afectado. Esto no resta importancia al riesgo de forma aislada, sino que refleja que su impacto proporcional en los indicadores de riesgo total es menor cuando el activo es menos crítico.

Con ello, podemos calcular los dos indicadores de riesgo total del sistema. Por un lado, el riesgo potencial total es el máximo de los niveles de riesgo relativos originales (es decir, sin tener en cuenta los riesgos propagados).

$$\text{Riesgo}_{\text{potencial total}} = \max_{i=1,\dots,n} \{ro_i\} \quad (4)$$

Donde ro_i hace referencia a cada uno de los riesgos relativos originales que afectan a activos del sistema y n es el número total de riesgos originales.

Por otro lado, un indicador más completo es el riesgo propagado total del sistema, que tiene en cuenta todos los riesgos, tanto originales como propagados. Su cálculo es similar al anterior:

$$\text{Riesgo}_{\text{propagado total}} = \max_{i=1,\dots,n} \{r_i\} \quad (5)$$

Donde r_i hace referencia a cada uno de los riesgos relativos que afectan a activos del sistema y n es el número total de riesgos.

De esta manera, el sistema es tan vulnerable como su debilidad más crítica, teniendo en cuenta la importancia respecto al propio sistema de los activos a los que afectan dichas debilidades.

IV. VALIDACIÓN

En esta sección se valida la metodología desarrollada previamente mediante un caso de uso práctico. El sistema de ejemplo simplifica un entorno corporativo que incluye cuatro activos: un ordenador del administrador del sistema, un servidor de identidad para autenticación, una terminal de visualización CCTV y un sistema de gestión de registros para

auditoría (Tabla I). Los valores de importancia reflejan la relevancia relativa de cada uno de los activos con respecto al sistema completo.

Tabla I
CATÁLOGO DE ACTIVOS DEL SISTEMA

Identificador	Clase	Nombre	Importancia
Activo 1	Hardware	Ordenador	0.9
Activo 2	Funciones	Servidor de Identidad	1
Activo 3	Hardware	Terminal CCTV	0.4
Activo 4	Datos	Sistema de Gestión de Logs	0.7

Estos activos están relacionados entre sí, formando una red por la que podrían propagarse los riesgos ante la llegada de un incidente. El ordenador y el servidor de identidad forman una relación bidireccional de criticidad máxima (3). Por otro lado, el ordenador presenta una relación de criticidad 1 con la terminal CCTV y, por último, el servidor está relacionado con el sistema de gestión de registros con criticidad 2. Se muestra un resumen de estas relaciones en la Tabla II.

Tabla II
CATÁLOGO DE RELACIONES ENTRE ACTIVOS

Origen	Destino	Bidireccional	Criticidad
Ordenador	Servidor de Identidad	Sí	3
Ordenador	Terminal CCTV	No	1
Servidor de Identidad	Sistema de Gestión de Logs	No	2

Tras realizar un estudio sobre el sistema propuesto, se realiza un catálogo de eventos temidos que afectarían gravemente al sistema y de los escenarios de amenaza involucrados, que se resumen en la Tabla III.

Si se registra un incidente que alerta de una amenaza de correo de *phishing* sobre el ordenador del administrador, el sistema analiza si tiene un evento temido asociado. Para ello, se busca el par amenaza-activo formado por el correo y el ordenador en el catálogo de escenarios de amenaza (Tabla III) y se confirma que puede materializarse en una posible instalación de *malware* con una probabilidad de 4 sobre 5 e impacto 7 sobre 10.

Para estudiar el riesgo potencial asociado a este evento temido original, utilizamos la Ec. (1):

$$\text{Riesgo potencial 1} = 4 \times 7 = 28$$

Tras valorar cómo afecta la amenaza recibida al ordenador del administrador, se estudia su posible propagación en el sistema. Para ello, se necesita el catálogo que incluye las reglas de propagación (Tabla IV).

Se observa en el catálogo que el evento temido de instalación de *malware* propaga una amenaza de secuestro de sesión sobre todas las relaciones del ordenador que tengan criticidad mínima 3. El sistema analiza las relaciones del ordenador, concluyendo que la única que cumple este criterio es la relación con el servidor de identidad.

A continuación, se estudia si la amenaza propagada de secuestro de sesión tiene un evento temido asociado y, tras buscar el par amenaza-activo formado por el secuestro y el servidor de identidad en el catálogo Tabla III, se confirma que genera un posible compromiso de la cuenta Admin con probabilidad 4 e impacto máximo.

Al igual que en el estudio del riesgo potencial anterior, utilizamos de nuevo la Ec. (1):

$$\text{Riesgo potencial 2} = 4 \times 10 = 40$$

Se continúa el estudio de la propagación del incidente registrado en el sistema, tratando la posible propagación del evento de compromiso de la cuenta Admin. Para ello, se consulta el catálogo de reglas de propagación y se observa que coincide con dos entradas. La primera identifica una amenaza de ataque de movimiento lateral. Dado que presenta una criticidad mínima de 2, los dos activos relacionados con el servidor de identidad podrían ser afectados: el ordenador (relación bidireccional de criticidad 3) y el sistema de gestión de logs (criticidad 2). En ambos casos se valida el cumplimiento del criterio de criticidad. Por otro lado, la segunda entrada identifica una amenaza de *ransomware* con una criticidad mínima de 3. En consecuencia, el único activo relacionado que podría propagar esta nueva amenaza es el ordenador y se generan las tres amenazas propagadas (movimiento lateral y *ransomware* sobre ordenador y movimiento lateral sobre el sistema de gestión de logs).

Seguidamente, se estudia si estos tres pares amenaza-activo están presentes en el catálogo de escenarios de amenaza (Tabla III). Se observa que no hay entradas asociadas a la amenaza de movimiento lateral. En consecuencia, no genera evento temido en ningún activo. Como el par (*ransomware*-ordenador) sí está presente y su entrada asociada indica que genera un evento temido de cifrado de archivos críticos con probabilidad 4 e impacto 9.

En la Fig. 1 se muestra la situación del sistema en este punto.




Figura 1. Caso de uso: Propagación - Paso 2

Para calcular su riesgo potencial, se sigue el mismo procedimiento de los cálculos anteriores:

$$\text{Riesgo potencial 3} = 4 \times 9 = 36$$

Como el evento temido de cifrado de archivos críticos no tiene ninguna regla de propagación asociada (Tabla IV), se da por concluido el estudio de esta propagación y se da paso a la valoración de los activos del sistema tras ella.

Los activos del sistema afectados por una amenaza al final del análisis que realiza el sistema son el ordenador del administrador (Activo 1) y el servidor de identidad (Activo 2). El primero tiene dos riesgos asociados: el riesgo potencial original de instalación de malware y el riesgo potencial

Tabla III
CATÁLOGO DE ESCENARIOS DE AMENAZA.

Amenaza	Evento temido	Activo	Probabilidad	Impacto
Correo de <i>Phishing</i>	Instalación de <i>Malware</i>	Ordenador	4	7
Secuestro de Sesión	Compromiso de Cuenta Admin	Servidor de Identidad	4	10
<i>Ransomware</i>	Cifrado de Archivos Críticos	Ordenador	4	9

Tabla IV
CATÁLOGO DE REGLAS DE PROPAGACIÓN EN EL SISTEMA.

Evento temido	Amenaza	Criticidad mínima
Instalación de <i>Malware</i>	Secuestro de Sesión	3
Compromiso de Cuenta Admin	Movimiento Lateral	2
Compromiso de Cuenta Admin	<i>Ransomware</i>	3

propagado de cifrado de archivos críticos. Para obtener el riesgo del activo se aplica la *Ec. (2)*.

$$R_{\text{Activo 1}} = \max\{R. \text{ pot. 1}, R. \text{ pot. 3}\} = \max\{28, 36\} = 36$$

El riesgo asociado al ordenador es de 36, que representa un riesgo ‘Muy Alto - Crítico’. En cuanto al servidor de identidad, al estar afectado por tan solo una amenaza, su riesgo es igual al generado por ella (Riesgo potencial 2), es decir, 40. Este valor representa un riesgo ‘Crítico’.

Tras evaluar el riesgo de los activos del sistema, se calculan los indicadores del sistema completo. Para ello, en primer lugar se calculan los valores de riesgo relativo de cada uno de los tres riesgos presentes en el sistema siguiendo la *Ec. (3)*. El valor de importancia utilizado en cada caso es el del activo afectado por el riesgo (*Tabla I*).

$$\text{Riesgo relativo 1} = \lceil 28 \times 0,9 \rceil = 26$$

$$\text{Riesgo relativo 2} = \lceil 40 \times 1 \rceil = 40$$

$$\text{Riesgo relativo 3} = \lceil 36 \times 0,9 \rceil = 33$$

Tras realizar estos cálculos, se procede a obtener los dos indicadores del sistema. Por un lado, el indicador de riesgo potencial total es igual al Riesgo relativo 1 debido a que es el único original presente en el sistema. Como consecuencia, este primer indicador nos alerta de un riesgo de valor 26, de nivel ‘Muy Alto’.

Por otro lado, el indicador de riesgo propagado total se calcula siguiendo la *Ec. (5)*.

$$T_{\text{propagado total}} = \max_{i=1,\dots,3} \{R \text{ rel. } i\} = \max\{26, 40, 33\} = 40$$

El resultado, 40, alerta de que el sistema está sometido a un riesgo propagado total ‘Crítico’. En este caso, el riesgo relativo máximo coincide con el riesgo potencial máximo, ya que el activo más importante es el más afectado.

La diferencia numérica entre ambos indicadores resalta la necesidad del estudio de la propagación al realizar una gestión de riesgos. En un primer momento, la amenaza de correo de *phishing* recibida representa un riesgo ‘Muy Alto’ en el sistema. Sin embargo, tras seguir la metodología propuesta, se observa que el riesgo al que podría estar sometido el sistema si esta se extiende por la red es ‘Crítico’. De esta manera, el plan de respuesta ante los riesgos recibidos deberá adecuarse

a las posibles situaciones de riesgo propagado, obteniendo un tratamiento más adecuado que si no se hubiera estudiado la propagación.

V. CONCLUSIONES Y LÍNEAS FUTURAS

El aumento de la interconectividad y la complejidad de los sistemas hace que los riesgos ya no afecten a un único activo, sino que se propaguen a través de dependencias críticas. Esto evidencia las limitaciones de los modelos tradicionales de gestión de riesgos, centrados en análisis estáticos, y resalta la necesidad de enfoques capaces de representar la evolución del riesgo en sistemas distribuidos.

La metodología propuesta modela la propagación del riesgo mediante la integración de relaciones entre activos, escenarios de amenaza y reglas de transmisión, permitiendo capturar efectos en cascada no considerados en modelos estáticos. La validación confirma que el riesgo propagado puede alterar significativamente los niveles de criticidad, lo que demuestra la importancia de incluir este análisis en la gestión de riesgos.

Como líneas futuras, se plantea incorporar contramedidas y riesgo residual dentro del ciclo de gestión, así como mejorar la caracterización de dependencias y automatizar la generación de reglas y escenarios para aumentar la escalabilidad y precisión del modelo.

AGRADECIMIENTOS

Este trabajo ha sido financiado parcialmente a través del programa de actividades de I+D con referencia TEC-2024/COM-504 y acrónimo RAMONES-CM, concedido por la Comunidad de Madrid, España, a través de la Dirección General de Investigación e Innovación Tecnológica mediante la Orden 5696/2024.

REFERENCIAS

- [1] Jamila Boutemour, Ifigeneia Lella, Ilias Bakatsis, Georgios Chatzichristos, Kevin Foley, Jussi Leskinen, Jakub Otčenasek, Dominik Ziolk, ENISA: ENISA threat landscape 2025. Accedido: 4 de febrero de 2026. [En línea]. Disponible en: DOI: 10.2824/1946374.
- [2] European Union Agency for Cybersecurity. “Interoperable EU risk management framework: methodology for and assessment of interoperability among risk management frameworks and methodologies.” Publications Office, 2022.
- [3] Pavlos Cheimonidis y Konstantinos Rantos: “Dynamic Risk Assessment in Cybersecurity: A Systematic Literature Review”, en *Future Internet* vol. 15, 2023.
- [4] IBM. “¿Qué es la gestión de riesgos?”. Accedido: 5 de febrero de 2026. [En línea]. Disponible en: <https://www.ibm.com/think/topics/risk-management>
- [5] International Organization for Standardization & International Electrotechnical Commission. (2018). Information technology — Security techniques — Information security management systems — Overview and vocabulary (ISO/IEC Standard No. 27000:2018). <https://www.iso.org/standard/73906.html>
- [6] Joël HUBIN: “Description of the methodology: IT Security Risk Management Methodology v1.2” DG DIGIT, 2020.
- [7] Mattia Fumagalli, Gal Engelberg, Tiago P. Sales, Ítalo Oliveira, Dan Klein, Pnina Soffer, Riccardo Baratella y Giancarlo Guizzardi. “On the Semantics of Risk Propagation”, en *Research Challenges in Information Science: Information Science and the Connected World*, pp. 69-86, 2023.

Sesión de Transferencia 2 - Arquitecturas de confianza, identidad y protección de infraestructuras

Entropía Cuántica Verificable en Infraestructuras PKI: Integración de un Generador Cuántico de Números Aleatorios (QRNG) en LamassuIoT

Haritz Saiz Sierra*, David Gilarranz Ortega*, Marc Romeu Casas†, David Cirauqui García†,
Fernando de la Iglesia Medina†, and José Ramón Martínez Saavedra†

*Ikerlan, Basque Research and Technology Alliance, Arrasate-Mondragon, Spain
{hsaiz, dgilarranz}@ikerlan.es

†Quside Technologies SL, Carrer d'Esteve Terradas, 1, Castelldefels, 08860, Barcelona, Spain.
{mromeu, dcirauqui, fdelaiglesia, jmartinez}@quside.com

Resumen—La transición hacia criptografía resistente a la computación cuántica ha centrado la atención en nuevos algoritmos, pero la calidad de la entropía empleada en la generación de claves continúa siendo un factor crítico y frecuentemente subestimado. Este trabajo presenta la integración de un generador cuántico de números aleatorios hardware en la infraestructura PKI IoT Lamassu, mediante una arquitectura desacoplada que permite sustituir la fuente de aleatoriedad sin modificar la lógica criptográfica. Se describe el rediseño del consumo de entropía, la interoperabilidad con Go a través de una capa de abstracción y la incorporación de métricas internas de calidad asociadas como metadatos a claves y certificados. Además, se lleva a cabo una evaluación estadística basada en NIST SP 800-90B para verificar la calidad de la entropía. Los resultados muestran mejoras en trazabilidad, auditabilidad y control objetivo de la calidad criptográfica.

Index Terms—Ciberseguridad, PKI, QRNG, RNG, TRNG, Criptografía

Tipo de contribución: *Transferencia*

I. INTRODUCCIÓN

En los últimos años, la criptografía se ha centrado en diseñar y estandarizar algoritmos resistentes a la computación cuántica o PQC. Organismos como NIST han impulsado procesos de evaluación para seleccionar esquemas criptográficos capaces de resistir ataques basados en futuros ordenadores cuánticos. Sin embargo, en este proceso de transición hacia algoritmos más robustos frente a nuevas capacidades de cómputo, existe un aspecto fundamental que con frecuencia recibe menor atención: la calidad de la entropía empleada en la generación de claves y parámetros criptográficos.

Los algoritmos PQC, al igual que los clásicos, dependen de números aleatorios para generar claves privadas, semillas, *nonces* y valores efímeros. Si esos valores no son verdaderamente impredecibles, la seguridad del sistema se debilita independientemente de la fortaleza matemática del algoritmo subyacente [?]. De esta manera, disponer de los mejores esquemas criptográficos pierde relevancia si las claves derivadas son parcialmente predecibles o “reversibles” debido a una entropía insuficiente. La calidad de los números aleatorios es, en este sentido, el gran olvidado de muchas discusiones sobre criptografía post-cuántica: un pilar silencioso que, si falla, compromete toda la arquitectura de seguridad.

En este contexto, la viabilidad de las infraestructuras de clave pública (PKI) en entornos industriales y de Internet de las Cosas (IoT) depende de manera crítica de la calidad

e impredecibilidad de los secretos criptográficos generados. Históricamente, los sistemas basados en software han recurrido a generadores de números pseudoaleatorios (PRNG) que, por su naturaleza algorítmica y finita, pueden presentar patrones de predictibilidad o sufrir de “falta de entropía” en escenarios de alta demanda o en sistemas con fuentes físicas limitadas.

La colaboración entre Quside e Ikerlan aborda esta vulnerabilidad estructural mediante la integración de la *Randomness Processing Unit* (RPU) Garnet(TM) Plus A41[?] en la PKI Lamassu IoT [?]. La RPU es un *Quantum Random Number Generator* (QRNG), una forma avanzada de *True Random Number Generator* (TRNG) que obtiene su entropía directamente de fenómenos físicos cuánticos intrínsecamente impredecibles. Este hardware produce números aleatorios proporcionando entropía de alta calidad de forma acelerada y optimizada.

Este trabajo ha explorado la integración de la RPU de Quside en la PKI *open source* Lamassu IoT con el objetivo de garantizar la generación de material criptográfico sustentado en parámetros de calidad de entropía cuantificables, verificables y medibles de forma objetiva.

II. ARQUITECTURA DE SISTEMAS Y SERVICIOS PKI

La arquitectura de Lamassu ha sido concebida bajo principios de modularidad y desacoplamiento, apoyándose en una estructura de microservicios que permite sustituir o ampliar componentes tecnológicos sin alterar la lógica central del sistema. Este enfoque ha resultado determinante para integrar la tecnología de Quside de forma controlada y no invasiva, preservando la estabilidad del núcleo de la PKI.

En este contexto, el Servicio de Gestión de Claves (KMS) de Lamassu desempeña un papel crítico. No actúa únicamente como un intermediario entre las solicitudes de certificación y los motores criptográficos, sino que constituye el núcleo operativo de todas las operaciones criptográficas sensibles del sistema. Es el servicio responsable de la generación de claves criptográficas, tanto para autoridades certificadoras (*Root* e *Intermediate CAs*) como para certificados finales (*leaf* o *end-entity certificates*), así como otras operaciones de firma digital (como la emisión de listas de revocación o CRLs, respuestas OCSP o incluso de operaciones de firmas digitales más genéricas para casos de uso más amplios).




Figura 1. Integración de la RPU en la arquitectura de la PKI Lamassu IoT

III. AISLAMIENTO DEL CONSUMO DE ENTROPÍA

Inicialmente, el módulo KMS no hacía uso de ningún patrón de diseño ni de una función centralizada para la gestión de la entropía. Por el contrario, se recurría directamente a las primitivas estándar que ofrece el propio lenguaje Go, concretamente al paquete `crypto/rand`, invocándolo de manera distribuida en distintos puntos del servicio cada vez que era necesario generar claves o realizar operaciones de firma probabilísticas. Esta aproximación, aunque funcional y sencilla, implicaba múltiples importaciones y dependencias directas a la fuente de aleatoriedad del sistema, dificultando cualquier sustitución futura.

Conviene destacar que Go proporciona diferentes mecanismos relacionados con la generación de números aleatorios bajo el patrón de la interfaz `rand.Read`. Entre ellos se encuentran 2 implementaciones oficiales, `math/rand` y `crypto/rand`, con propósitos claramente diferenciados. La primera está orientada a simulaciones y usos no criptográficos, basándose en generadores pseudoaleatorios deterministas de bajo coste computacional y alta velocidad. La segunda, `crypto/rand`, está diseñada específicamente para aplicaciones criptográficas y obtiene entropía del sistema operativo o de mecanismos criptográficamente seguros, con mayores garantías de impredecibilidad pero también con un mayor coste en tiempo de cómputo. En el caso de Lamassu, se empleaba exclusivamente `crypto/rand`, pero sin una capa de abstracción que desacoplara su uso.

Como parte del trabajo previo de refactorización, se desarrolló una nueva utilidad encargada exclusivamente de proveer la entropía al resto del servicio, encapsulando esta responsabilidad en una interfaz única. De este modo, se eliminó la necesidad de importar y utilizar `crypto/rand` en múltiples ubicaciones del código, centralizando toda la lógica en un único punto. Para los escenarios sin RPU, esta utilidad sigue utilizando internamente `crypto/rand`, pero ahora a

través de una única función, lo que permite intercambiar su implementación de forma transparente por otra fuente, como la RPU de Quside, sin alterar la lógica del KMS ni del resto del sistema.

Al disponer de un único punto de entrada para el consumo de entropía, resulta posible auditar, monitorizar y eventualmente aplicar políticas sobre su uso, algo que anteriormente era mucho más complejo debido a la dispersión de llamadas directas a las primitivas del lenguaje. Además, este enfoque sienta las bases para futuras extensiones, como la incorporación de mecanismos de *fallback*, selección dinámica de fuentes de entropía o aplicación de criterios basados en métricas de calidad, reforzando así la mantenibilidad y evolución del servicio a largo plazo.

IV. INTEGRACIÓN DE LA RPU EN LA PKI

La integración de la RPU en la PKI comenzó con la adopción física del hardware, que se conecta al host mediante una interfaz PCIe Gen 2 x4, permitiendo un acceso de alta velocidad y baja latencia a la fuente de entropía cuántica. Debido a que la API de la RPU está disponible nativamente en C, se aprovechó la capacidad de `cgo` para realizar una integración directa y construir un SDK que controla el dispositivo desde Go.

Bajo este enfoque de interoperabilidad nativa, se desarrolló un SDK específico que encapsula las llamadas a la librería dinámica de Quside y gestiona automáticamente procesos críticos, como la comprobación del estado y la calibración de la RPU. Esta capa intermedia permite desacoplar el sistema de los detalles de bajo nivel, obteniendo un SDK perfectamente integrado en el ecosistema de Go.

Una vez implementado el SDK, el siguiente paso consistió en integrarlo de forma transparente dentro del flujo criptográfico del sistema. Para ello, se desarrolló una implementación compatible con la interfaz utilizada por las primitivas estándar

de generación de aleatoriedad en Go, concretamente la interfaz `rand.Read`, empleado internamente por la implementación de `crypto/rand`. De esta forma, la RPU pasó a comportarse como una fuente de entropía interoperable en Go, permitiendo sustituir la implementación software por la fuente cuántica sin modificar la lógica criptográfica del KMS ni del resto de los servicios de la PKI.

V. MONITORIZACIÓN Y ANÁLISIS DE RENDIMIENTO

Uno de los objetivos del proyecto fue dotar a la PKI de mayor observabilidad, tanto funcional como criptográfica, instrumentando el sistema para medir las llamadas a las primitivas de generación de aleatoriedad y correlacionarlas con operaciones como la generación de claves o la emisión de certificados. De este modo, no solo se medía el tiempo total de ejecución de una operación criptográfica, sino también el consumo real de entropía subyacente asociado a dicha operación.

En ECDSA, la generación de clave privada consiste en obtener un único valor aleatorio dentro del rango de la curva (≈ 256 bits en P-256), normalmente mediante una sola lectura de entropía, lo que produce tiempos de ejecución estables [?].

El escenario cambia de forma significativa en RSA. Para generar una clave RSA de, por ejemplo, 2048 bits, es necesario obtener dos números primos grandes e independientes. Esto implica un proceso iterativo: se generan números aleatorios de gran tamaño y se someten a pruebas de primalidad. Si el número no es primo, se descarta y se genera uno nuevo [?]. Desde el punto de vista de la observabilidad, esto se traduce en múltiples llamadas a la primitiva de generación de entropía, cuyo número es inherentemente variable. Aunque la entropía pueda extraerse en bloques, el proceso de búsqueda de primos introduce un comportamiento no determinista en tiempo y consumo.

La experimentación llevada a cabo confirma esta naturaleza impredecible del proceso RSA. En algunos casos, la generación de una clave se ha completado tras un número relativamente bajo de intentos, mientras que en otros ha sido necesario realizar muchas más iteraciones antes de encontrar primos válidos. Se han observado diferencias de hasta un factor de 36 entre el mejor y el peor caso en términos de tiempo de ejecución. Esta variabilidad no responde a ineficiencias del sistema, sino al propio diseño probabilístico del algoritmo: se generan N números aleatorios y se comprueba si son primos, repitiendo el proceso hasta cumplir la condición matemática requerida.

La capacidad de medir estas diferencias y asociarlas directamente al número de lecturas de entropía ha permitido comprender mejor el impacto real de la fuente aleatoria en el comportamiento del sistema. Este enfoque no solo aporta transparencia técnica, sino que proporciona datos cuantitativos para evaluar el efecto de integrar una fuente de entropía hardware como la RPU frente a las implementaciones puramente software.

Además de actuar como fuente de entropía física, la RPU proporciona un conjunto de parámetros internos de calidad que permiten cuantificar de forma objetiva el estado y comportamiento del generador en el momento de cada operación, así como, de forma fundamental, medidas en tiempo de ejecución de la impredecibilidad del sistema. Entre estos parámetros

destacan como medidas de la calidad de la entropía proporcionada y la impredecibilidad del dispositivo [?], [?], [?], [?]:

- *QFactor*: medida estadística que reúne aspectos de "running average" (equilibrio entre el número de 1s y de 0s que aparecen en las secuencias de números) como aspectos de correlación de las secuencias a distintas distancias. Su valor esperado en un comportamiento saludable es > 0.979
- *Running average*: mide de forma precisa el equilibrio entre la cantidad de 0s y 1s de las secuencias producidas. Su valor saludable es 0.5 ± 0.0001
- $H_{\min}$: mide la entropía cuántica mínima condicionada y ofrece una medida sobre la impredecibilidad de la fuente de entropía (a diferencia de las medidas sobre las secuencias de números producidas). Su valor esperado en comportamiento saludable es > 0.928
- $h_{\min}^{RTO}$: es una medida estimada de $H_{\min}$ para ser obtenida de forma rápida en semi tiempo real. Su valor esperado en comportamiento saludable es > 0.928

Estos indicadores aportan una ventaja frente a fuentes software, donde la calidad de la entropía suele asumirse pero no medirse en tiempo real, al realizar operaciones criptográficas.

Añadido a lo anterior, la RPU proporciona monitorización de parámetros físicos que pueden afectar a su funcionamiento y por tanto a la calidad de la entropía y su impredecibilidad, como son la Temperatura de la tarjeta, el voltaje de comparación para la discriminación de valores de potencia, la potencia de los láseres, etc.

La integración realizada va un paso más allá de la mera sustitución de la fuente de aleatoriedad. Las métricas proporcionadas por la RPU son consumidas y asociadas como metadatos a las entidades generadas por la PKI, tales como claves privadas, certificados y otros artefactos criptográficos. De este modo, cada objeto almacenado en la PKI puede vincularse al estado concreto de la entropía en el instante de su creación. Esto permite realizar consultas posteriores para identificar qué entidades fueron generadas bajo valores subóptimos o fuera de los umbrales recomendados, habilitando mecanismos de auditoría, trazabilidad y eventualmente políticas de renovación preventiva. Con ello, la calidad de la entropía deja de ser un supuesto implícito y pasa a convertirse en un atributo explícito y verificable dentro del ciclo de vida de los activos criptográficos, aumentando la visibilidad sobre aspectos fundamentales, elevando así el posicionamiento de seguridad del sistema.

VI. EVALUACIÓN DE LA CALIDAD DE LA ENTROPÍA

La integración de una nueva fuente de entropía en una infraestructura PKI no puede considerarse completa sin una evaluación técnica que analice la calidad criptográfica de la aleatoriedad. Por ello, se ha realizado un análisis estadístico formal de la entropía generada, con el objetivo de cuantificar de manera objetiva su nivel de impredecibilidad y estabilidad.

La validación se llevó a cabo utilizando el conjunto de herramientas definido en el estándar NIST SP 800-90B [?], específicamente diseñado para la estimación de entropía en fuentes físicas no deterministas. Se generaron más de 1.000 capturas independientes por cada fuente evaluada, manteniendo constantes tanto el tamaño de los conjuntos de datos como

el procedimiento de adquisición, con el fin de asegurar la comparabilidad de los resultados. Cada muestra fue procesada mediante el módulo de análisis *non-IID*, que aplica distintos estimadores estadísticos, entre ellos *Most Common Value*, *Collision*, *Markov*, *Compression*, *Tuple* y *LRS*, para detectar posibles sesgos o dependencias internas en la secuencia generada.

Se evaluaron cinco fuentes: la RPU de Quside, `crypto/rand` y `math/rand` del runtime de Go tanto en la versión anterior como en la versión 1.22 (que introduce ChaCha8 como generador por defecto). La Tabla ?? resume las métricas de entropía principales.

Tabla I
MÉTRICAS DE ENTROPÍA NIST SP 800-90B (PROMEDIO, >1.000 CAPTURAS POR FUENTE, PALABRA DE 8 BITS).

Fuente	$h_{\text{Bitstring}}$	h_{Assessed}	h_{Original}
<code>crypto/rand</code>	0,9056	7,1364	7,2977
<code>crypto/rand v1.22</code>	0,9056	7,1310	7,3005
<code>math/rand</code>	0,9045	7,1160	7,2996
<code>math/rand v1.22</code>	0,9043	7,1194	7,3003
RPU Quside	0,9048	7,1240	7,3084

Los resultados muestran que todas las fuentes evaluadas presentan niveles de entropía consistentemente elevados. La entropía estimada (h_{Assessed}) supera los 7 bits por byte en todos los generadores, un valor próximo al máximo teórico de 8 bits, confirmando la calidad criptográfica de las secuencias producidas. La variabilidad observada en la fuente física se limita a casos aislados y no afecta a su rendimiento global de entropía.

Adicionalmente, se realizó una validación estadística formal mediante comparación entre fuentes, aplicando un umbral de significancia ajustado ($p < 0,05$). Las comparaciones entre la RPU de Quside y las implementaciones de Go 1.22, basadas en ChaCha8, arrojaron resultados no significativos en la totalidad de los 10 tests del conjunto NIST SP 800-90B. Esto confirma que la fuente cuántica proporciona una calidad estadística equiparable a las mejores implementaciones software actuales, con la ventaja adicional de ofrecer entropía física verificable, medible en tiempo real y respaldada por hardware dedicado, lo que proporciona garantías que una implementación puramente software no puede ofrecer por diseño.

VII. CONCLUSIONES

Este trabajo aborda un aspecto frecuentemente subestimado en el diseño de infraestructuras criptográficas: la calidad y trazabilidad de la entropía utilizada en la generación de material criptográfico. Más allá de la robustez algorítmica, se demuestra que la fuente de aleatoriedad es un elemento estructural cuya debilidad puede comprometer la seguridad global del sistema.

La integración de un generador cuántico de números aleatorios en la PKI Lamassu IoT se ha realizado mediante un rediseño arquitectónico basado en el desacoplamiento del consumo de entropía, permitiendo sustituir la fuente subyacente sin alterar la lógica criptográfica del sistema. La encapsulación de la aleatoriedad en una interfaz única no solo ha facilitado la interoperabilidad con hardware especializado, sino que ha mejorado la auditabilidad y mantenibilidad del servicio.

Los resultados experimentales muestran el comportamiento diferencial del consumo de entropía en algoritmos como ECDSA y RSA, evidenciando la naturaleza inherentemente probabilística de este último y su impacto en rendimiento y variabilidad temporal. Asimismo, la evaluación estadística conforme a NIST SP 800-90B confirma la estabilidad y calidad de la fuente física integrada.

Más allá de sustituir la fuente de aleatoriedad, la principal aportación del trabajo es incorporar métricas objetivas de calidad de entropía como metadatos asociados a claves y certificados. Este enfoque convierte la entropía de un supuesto implícito en un atributo explícito, medible y verificable durante todo el ciclo de vida de los activos criptográficos, habilitando mecanismos de trazabilidad, auditoría y gestión preventiva, y reforzando la seguridad de la PKI Lamassu IoT.

Como líneas futuras, se plantea la definición de políticas dinámicas basadas en umbrales de calidad, mecanismos automáticos de renovación de activos generados bajo condiciones subóptimas y la extensión del modelo a entornos híbridos que combinen criptografía post-cuántica con fuentes de entropía física certificadas.

En conjunto, este trabajo sienta las bases para una concepción más integral de la seguridad criptográfica en entornos IoT industriales, donde la calidad de la entropía deja de ser un componente invisible para convertirse en un parámetro gestionado explícitamente dentro de la infraestructura PKI.

VIII. AGRADECIMIENTOS

Este trabajo ha sido financiado por el Consejo Europeo de Innovación (EIC) en el marco del programa de investigación e innovación *Horizon Europe* de la Unión Europea, Acuerdo de Subvención n.º 101145131 (RPU) así como por la Unión Europea a través del proyecto CAPSARII del Fondo Europeo de Defensa (EDF), con número de subvención 101168102.

REFERENCIAS

- [1] J. Kilgallin and R. Vasko, "Factoring RSA Keys in the IoT Era," 2019 First IEEE International Conference on Trust, Privacy and Security in Intelligent Systems and Applications (TPS-ISA), Los Angeles, CA, USA, 2019, pp. 184-189, doi: 10.1109/TPS-ISA48467.2019.00030.
- [2] Quside, "Garnet™ Plus A41 Datasheet", <https://quside.com/wp-content/uploads/2023/06/Quside-Garnet-Plus-A41-Datasheet-3.pdf>.
- [3] LKS Next, "LamassuIoT", <https://www.lamassu.io/>.
- [4] National Institute of Standards and Technology, "Digital Signature Standard (DSS)". (Department of Commerce, Washington, D.C.), Federal Information Processing Standards Publications (FIPS) 186-5, 2023.
- [5] M. W. Mitchell, C. Abellan, and W. Amaya, "Strong experimental guarantees in ultrafast quantum random number generation", *Phys. Rev. A*, vol. 91, 012314, 2015. <https://doi.org/10.1103/PhysRevA.91.012314>.
- [6] C. Abellán, W. Amaya, M. Jofre, M. Curty, A. Acín, J. Capmany, V. Pruneri, and M. W. Mitchell, "Ultra-fast quantum randomness generation by accelerated phase diffusion in a pulsed laser diode", *Opt. Express*, vol. 22, pp. 1645-1654, 2014. <https://doi.org/10.1364/OE.22.001645>.
- [7] C. Abellan, W. Amaya, D. Domenech, P. Muñoz, J. Capmany, S. Longhi, M. W. Mitchell, and V. Pruneri, "Quantum entropy source on an InP photonic integrated circuit for random number generation", *Optica*, vol. 3, pp. 989-994, 2016. <https://doi.org/10.1364/OPTICA.3.000989>.
- [8] B. Hensen, H. Bernien, A. Dréau, et al., "Loophole-free Bell inequality violation using electron spins separated by 1.3 kilometres", *Nature*, vol. 526, pp. 682-686, 2015. <https://doi.org/10.1038/nature15759>.
- [9] M. S. Turan, E. Barker, J. Kelsey, K. A. McKay, M. L. Baish, and M. Boyle, "Recommendation for the Entropy Sources Used for Random Bit Generation", NIST SP 800-90B, 2018. <https://doi.org/10.6028/NIST.SP.800-90B>.

TrustDrive: Blockchain-Powered Driving Evidence Generation System

Carles Anglés-Tafalla,
Jordi Castellà-Roca y Alexandre Viejo
Universitat Rovira i Virgili,
Dept. d'Eng Inf i Mat, CYBERCAT,
{jordi.castella, carles.angles,
alexandre.viejo}@urv.cat

Josep M. Gastó
Fundació URV,
CYBERCAT,
43007 Tarragona, Spain,
jmgasto@cristech.org

Resumen—The increasing digitalization of vehicles enables new opportunities for generating trustworthy digital evidence in traffic, regulatory, and insurance contexts. However, current vehicular evidence collection mechanisms, such as police reports or dashcam recordings, lack strong guarantees of authenticity, integrity, and privacy compliance, limiting their legal value and increasing litigation and enforcement costs.

This paper presents TrustDrive, a blockchain-powered vehicular evidence generation system designed to autonomously collect, process, and register tamper-proof driving-related incidents. The solution integrates vehicle-side sensing, cryptographic mechanisms, and a blockchain-based integrity layer to provide legal-admissible, GDPR-compliant digital evidence. Currently at TRL 3, TrustDrive has achieved an analytical and experimental proof-of-concept of its core components, including a modular vehicle-side prototype and a blockchain-based privacy-preserving integrity layer.

Beyond its technical architecture, this work emphasizes the transfer pathway from academic research to market-oriented innovation. We describe stakeholder engagement activities, intellectual property strategy development, and the roadmap toward TRL 6 validation through pilot deployment in restricted vehicular zones. The paper illustrates how structured collaboration, regulatory alignment, and strategic valorization can enable the progressive transfer of blockchain-based security solutions into real-world smart mobility ecosystems.

Index Terms—Blockchain, Vehicular Forensics, Vehicular Crowdsourcing, Technology Transfer, Smart Mobility

Type of contribution: *Technology Transfer Article*

I. INTRODUCTION

The increasing digitalization of the automotive sector is transforming vehicles into highly connected systems equipped with advanced sensing, communication, and processing capabilities. Modern vehicles integrate cameras, GNSS positioning (GPS/Galileo), telemetry systems, and Vehicle-to-Everything (V2X) communication modules, enabling real-time interaction with their environment [1]. While these technologies were initially designed to enhance driving safety and automation, they have also opened new opportunities for generating digital vehicular evidence in traffic, regulatory, and insurance contexts.

Currently, traffic incidents, vehicular regulatory violations, and insurance claims are typically supported by police reports, eyewitness testimonies, telemetry logs or dashcam recordings. However, these sources often suffer from subjectivity, incomplete contextual information, or vulnerability to manipulation [2]. As a result, in legal and insurance scenarios, the

lack of guarantees of authenticity and integrity reduces the evidentiary value of such data, frequently leading to prolonged litigation processes, higher costs, and reduced trust among the involved parties.

TrustDrive addresses this gap by proposing a blockchain-powered vehicular evidence generation system capable of collecting, processing, and securely registering tamper-proof driving-related incidents. By integrating vehicle-side sensing technologies with cryptographic mechanisms and a blockchain-based integrity layer, TrustDrive aims to provide forensic-grade, GDPR-compliant digital evidence suitable for vehicular regulatory enforcement, insurance claim resolution, and legal dispute management.

Unlike conventional dashcam-based solutions, TrustDrive is designed as a forensic-grade evidence generation system rather than a simple recording device. The system digitally signs and encrypts relevant incident data, and registers cryptographic proofs on a blockchain network to guarantee integrity, traceability, and non-repudiation.

In addition, a privacy-aware backend infrastructure enables controlled access to anonymized or full versions of the evidence, depending on users' authorization and regulatory requirements. This approach addresses both the need for trust in evidential data and the strict regulatory requirements imposed on personal data processing.

This paper presents the transfer-oriented development of TrustDrive, describing its technological foundation, stakeholder engagement process, intellectual property strategy, and roadmap towards real-world deployment. Rather than only focusing on the technical design, we emphasize the knowledge transfer pathway from academic research in cryptography and blockchain systems to an applied solution aligned with industrial and regulatory needs. The work illustrates how blockchain-based security architectures research can evolve into a market-oriented innovation addressing concrete societal and economic challenges in smart mobility ecosystems.

II. PRIOR RESEARCH RESULTS AND TECHNOLOGICAL FOUNDATION

The scientific foundation of TrustDrive is grounded in previous research conducted over the last decade in vehicular sensing, digital forensics, and blockchain-based control systems for regulated mobility environments. Originally designed to assist drivers, vehicle-installed sensors and cameras

evolved into sophisticated data acquisition platforms. Modern vehicle platforms, such as Android Automotive OS (AAOS) and Android Auto, have accelerated this transformation by enabling vehicles to interact not only with drivers but also with their surrounding environment through real-time sensing, connectivity, and data exchange capabilities. This evolution created a technological foundation for moving from passive recording towards structured and verifiable vehicle digital evidence generation.

Several studies, including [3], [4], [5], [6], explore the use of dash cameras to collect evidence by surveilling their surroundings to report road incidents, traffic violations or tracking specific vehicles. In the context of sustainable mobility enforcement, the work of [7] proposes a collaborative surveillance approach where vehicles equipped with Automatic Number Plate Recognition (ANPR) cameras use Vehicle-to-Vehicle (V2V) communication to monitor and report to authorities unauthorized vehicles entering restricted zones. Similarly, [8] introduces a distributed system combining ANPR and V2V communication to detect toll evasion attempts on barrier-free highways.

Nevertheless, these approaches rely on posterior validation by authorities or collective witness reports, lacking an immutable and tamper-proof data layer that guarantees admissibility in legal and regulatory contexts.

To address this gap, several works have explored tamper-proof data generation mechanisms in vehicular forensics. The approach in [9] embeds watermarking information—such as timestamp and device metadata—into accident-related ANPR-images to verify data authenticity. Likewise, [10] proposes an incentive-driven system where vehicles and roadside units collaboratively capture and transmit incident images to the cloud for forensic analysis.

Further key precursors of TrustDrive are our prior works on blockchain-based mechanisms for regulating vehicular access to restricted mobility areas, particularly in the context of Congestion Charge (CC) and Low Emission Zones (LEZs) [11], [12]. In these proposals, smart contracts were employed to ensure transparency, traceability, and integrity in vehicular authorization processes. This research demonstrated that blockchain infrastructures can provide immutable auditability while preserving user privacy through advanced cryptographic techniques. The results of these works validated the feasibility of generating digital vehicular evidence with distributed ledger technologies in regulatory contexts.

Building on these academic foundations, TrustDrive extends the vehicular access control model towards a generalized legal-admissible evidence generation system. While earlier research focused on validating access permissions in restricted zones, TrustDrive broadens the scope to any driving-related incident, including regulatory violations, incident reconstruction, and compliance monitoring.

The technological architecture of TrustDrive integrates four core components:

- A vehicle-side *On-Board Unit (OBU) prototype* capable of collecting telemetry, positioning, and video inputs. A dedicated AAOS-based application is envisioned to provide the graphical user interface and interaction layer. This application interfaces with Evidence Generation

Module of the proposal to locally generate tamper-proof digital evidence.

- An *Evidence Generation Module* that structures incident data, applies advanced cryptographic mechanisms, and generates the necessary components to transform raw sensor data into legally admissible, tamper-proof digital evidence.
- A *Backend Infrastructure* incorporating privacy-preserving access control and anonymization mechanisms, enabling controlled disclosure of evidence in compliance with GDPR requirements.
- A *Blockchain layer* that registers cryptographic components and anonymized data of generated evidence. By anchoring cryptographic elements and integrity proofs on a distributed ledger, this layer ensures immutability, traceability, and non-repudiation.

From a maturity point of view, the project has reached Technology Readiness Level (TRL) 3 [13]. An experimental proof-of-concept has been developed, validating the feasibility of secure evidence generation and blockchain-based integrity anchoring under controlled laboratory conditions. Key components have been independently tested, including cryptographic primitives and smart contract registration on test networks. However, full system integration and real-world pilot validation remain part of the planned roadmap.

Importantly, the technological architecture has been designed with transferability in mind. Rather than relying on proprietary manufacturer-integrated OBUs, the current prototype is implemented on a modular single-board computer. This design choice enables flexible integration across vehicular platforms and facilitates pilot experimentation without dependency on automotive Original Equipment Manufacturer (OEM) restrictions.

The maturity of the cryptographic primitives, the prior validation of blockchain-based regulatory mechanisms, and the existence of a functional proof-of-concept collectively provide a solid technological baseline for advancing toward higher TRLs and real-world pilot deployment.

III. TRANSFER STRATEGY AND INDUSTRY COLLABORATION

The development of TrustDrive has been guided from its early stages by a transfer-oriented perspective, aiming to align scientific research outcomes with real industrial and regulatory needs. The transfer strategy of TrustDrive has been structured in four complementary operations: stakeholder engagement, intellectual property protection, business model validation, and progressive pilot deployment. The objective is to move from a research proof-of-concept (TRL 3) toward validation in relevant operational environments (TRL 6) through structured industrial collaboration.

III-A. Stakeholder Engagement and Use Case Definition

A structured stakeholder engagement process has been conducted to validate the practical applicability of the proposed system. Discussions have been conducted with APPlus+ IDIADA, AKKODIS, the Autoritat Portuària de Tarragona, and the Diputació de Tarragona to identify concrete use cases where tamper-proof vehicular evidence generation provides measurable value.

In particular, collaboration with automotive testing experts has contributed to assessing integration feasibility within vehicular environments. Engagement with regional public administrations and port authorities has helped define a realistic pilot scenario focused on enforcement in restricted vehicular areas, such as LEZs, CC and controlled port access environments. Additionally, discussions with mobility technology companies have facilitated alignment with ongoing European initiatives in connected vehicle ecosystems.

These interactions have resulted in three primary validated use cases: (i) regulatory enforcement in restricted traffic zones, (ii) insurance claim dispute resolution, and (iii) generation of trusted digital evidence for traffic incidents. Importantly, stakeholder feedback has been instrumental in refining system requirements, particularly regarding GDPR compliance and operational feasibility.

III-B. Intellectual Property and Commercialization Strategy

To ensure effective technology transfer, an initial intellectual property strategy has been defined (IPRL 3). This includes a preliminary patentability assessment and Freedom-to-Operate analysis to evaluate the protection potential of the tamper-proof evidence generation mechanism and its blockchain-based integrity anchoring process.

The commercialization approach considers multiple transfer options, including technology licensing to mobility solution providers, integration partnerships with automotive testing and certification entities, and potential creation of a spin-off focused on digital vehicular evidence services. This multi-path strategy reduces dependency on a single commercialization model and increases flexibility for future deployment scenarios.

Although the project was initially submitted to a regional knowledge valorization program and reached advanced evaluation stages, alternative funding mechanisms are currently being pursued to support pilot deployment and further TRL progression. This process has strengthened the project's IP positioning, clarified ownership structures, and consolidated its long-term transfer roadmap.

III-C. Business Model Validation and Funding Roadmap

From a business perspective, TrustDrive is currently positioned at BRL 3 and CRL 3. A preliminary Business Model Canvas has been defined, identifying key target customers such as public administrations responsible for traffic regulation enforcement, insurance companies seeking reliable claims validation mechanisms, fleet operators, and mobility infrastructure managers.

Initial stakeholder feedback has confirmed the economic relevance of reducing litigation costs, minimizing fraud risks, and lowering infrastructure investments required for regulatory enforcement. In particular, replacing or complementing fixed enforcement infrastructures with distributed, vehicle-generated evidence presents a potentially scalable and cost-efficient alternative.

The current roadmap prioritizes the development of a functional prototype suitable for controlled pilot testing, followed by validation in a relevant operational environment to reach TRL 6. Parallel to technical maturation, funding efforts are

being directed toward public innovation programs, smart-mobility-focused grants, and strategic industrial partnerships.

IV. CURRENT RESULTS AND ROADMAP TO MARKET DEPLOYMENT

TrustDrive is currently positioned at TRL 3, with an analytical and experimental proof-of-concept of its core components already developed.

The main mechanisms for tamper-proof evidence generation (i.e. cryptographic methods, privacy-by-design protocols and blockchain-based integrity registry) have been implemented, tested, and validated under controlled laboratory conditions[12]. These experiments demonstrate the technical soundness of the proposed architecture, particularly regarding data immutability, traceability, and privacy-aware processing.

A modular vehicle-side prototype has been assembled using a single-board computer acting as a simulated OBU. This prototype enables the collection of telemetry and positioning data and supports the integration of camera-based inputs. In order to align the development path with current automotive industry trends, AAOS has been integrated into the simulated OBU environment as an experimental platform. This choice facilitates compatibility with emerging software-defined vehicle architectures and demonstrates the feasibility of future integration into manufacturer-native OBUs. Although not yet embedded in proprietary automotive platforms, this setup enables realistic experimentation and controlled validation without dependency on OEM-restricted environments.

On the server side, the backend infrastructure and blockchain layer architecture have been defined and partially implemented. Initial smart contract tests confirm the feasibility of registering and verifying cryptographic proofs of vehicular incidents on a blockchain test network, ensuring authenticity, immutability, and traceability of generated evidence. The integrity layer is currently implemented on an Ethereum-compatible test network, allowing smart-contract-based anchoring of cryptographic hashes.

The technological maturity achieved at this stage enabled the submission of the project to a regional knowledge valorization program. Although full funding was not secured in that call, the evaluation process contributed significantly to consolidating the technical roadmap and transfer strategy. In particular, reviewer feedback supported the refinement of the intellectual property protection approach, clarification of stakeholder alignment, and the definition of a pilot deployment plan.

The short-term roadmap focuses on advancing toward TRL 6 through three structured stages. First, a fully integrated functional prototype will be assembled, combining the vehicle-side module, user application interface, backend infrastructure, and blockchain layer (TRL 4). Second, controlled environment testing will be conducted to assess performance, operability, and regulatory compliance under simulated vehicular scenarios (TRL 5). Finally, pilot deployment in a stakeholder-defined relevant environment, such as restricted vehicular zones, will enable validation under real traffic conditions (TRL 6).

In parallel with technical maturation, efforts are being directed toward securing funding for pilot execution and strengthening industrial partnerships. The refinement of the

intellectual property strategy and the engagement of potential early adopters aim to reduce technological, regulatory, and market uncertainties before large-scale deployment.

This staged progression reflects a realistic and risk-aware transfer path. Rather than prematurely rush towards commercialization, the roadmap emphasizes the solution validation, its regulatory alignment, and stakeholder involvement for setting the prerequisites for a sustainable market entry.

V. EXPECTED IMPACT AND CONCLUSIONS

TrustDrive is positioned to generate an impact across regulatory, economic, and societal aspects within the smart mobility ecosystem.

From a regulatory perspective, the system provides a scalable mechanism for enforcing traffic and environmental regulations without relying exclusively on fixed infrastructure, particularly in restricted vehicular zones (e.g., CCs or LEZs) and controlled access infrastructures (e.g., ports or logistics hubs). By shifting from infrastructure surveillance approaches to in-vehicle evidence generation, the solution may reduce implementation and maintenance costs while increasing traceability and accountability. Furthermore, the generation of tamper-proof vehicular evidence enhances transparency and auditability in enforcement procedures, supporting public administrations in mobility governance.

Economically, TrustDrive addresses inefficiencies associated with insurance claim disputes, fraud detection, and litigation processes. By providing forensic-grade digital evidence with legal admissibility, the solution has the potential to reduce investigation times and administrative overhead. The distributed evidence-generation model may complement or partially replace costly enforcement infrastructures, improving cost-efficiency and scalability.

From a societal point of view, the availability of trustworthy vehicular evidence can increase confidence among drivers, authorities, insurers, and judicial actors. By reducing subjectivity and ambiguity in incident reconstruction, the system promotes fairness and transparency in mobility-related conflicts. Furthermore, the integration of a privacy-by-design paradigm ensures that tamper-proof requirements do not compromise data protection rights, aligning our solution with European regulatory standards.

Beyond its expected impact, the development of TrustDrive highlights several key conclusions regarding the knowledge transfer in *Security and Privacy-by-Design* mobility solutions.

First, access to proprietary automotive platforms remains a structural barrier for early-stage academic innovation. The implementation of a modular OBU prototype enabled technical validation without dependency on OEMs; however, long-term deployment will require strategic agreements with industrial partners or manufacturers.

Second, regulatory compliance, particularly regarding GDPR and evidentiary standards, must be integrated from the earliest design phases. In evidence-generation approaches, legal admissibility and privacy protection should be treated as critical as technical robustness.

Third, stakeholder engagement significantly shapes technological design. Early interactions with industry and public-sector actors helped to refine use cases, adapt architectural

decisions, and align development priorities with operational realities.

Finally, the progression from research prototype to deployable mobility solution requires coordinated advancement on technical validation, intellectual property strategy, funding planning, and business model refinement. Transfer readiness cannot be achieved through technical excellence alone; it requires coordinated development across technological, legal, and commercial areas.

These observations reinforce the importance of integrating technical development, regulatory alignment, and market validation in parallel. TrustDrive illustrates how privacy-by-design-oriented research can progressively evolve into a transfer-oriented innovation through structured stakeholder collaboration, iterative validation, and strategic alignment with regulatory and market requirements.

ACKNOWLEDGMENTS

This research is supported by the project “HERMES” funded by INCIBE and the European Union NextGenerationEU/PRTR; by projects SECURING/DATA (PID2021-125962OB-C32) and SAFE/DATA (PID2024-156914OB-C42) funded by MCIN/AEI/10.13039/501100011033/ FEDER, UE; and by the grant 2021SGR 00115 from the Government of Catalonia.

REFERENCIAS

- [1] K. Strandberg and M. Eldefrawy, “Advances in automotive digital forensics: Recent trends and future directions,” in *International Conference on Availability, Reliability and Security*. Springer, 2025, pp. 252–274.
- [2] K. K. G. Buquerin, C. Corbett, and H.-J. Hof, “A generalized approach to automotive forensics,” *Forensic Science International: Digital Investigation*, vol. 36, p. 301111, 2021.
- [3] A. D. Sathe and V. D. Deshmukh, “Advance vehicle-road interaction and vehicle monitoring system using smart phone applications,” in *2016 Online international conference on green engineering and technologies (IC-GET)*. IEEE, 2016, pp. 1–6.
- [4] M. Jameela, H. Afzal, K. Khurshid, and A. W. Malik, “Crowdsourced system to report traffic violations,” in *Proc. of the 4th Int. Conf. on Vehicle Technology and Intelligent Transport Systems (VEHITS-2018)*, Funchal, Madeira, Portugal, vol. 1, 2018.
- [5] H. Chen, B. Guo, Z. Yu, and Q. Han, “Crowdtracking: Real-time vehicle tracking through mobile crowdsensing,” *IEEE Internet of Things Journal*, vol. 6, no. 5, pp. 7570–7583, 2019.
- [6] Z. Jiang, H. Zhu, B. Zhou, C. Lu, M. Sun, X. Ma, X. Fan, C. Wang, and L. Chen, “Crowdpatrol: A mobile crowdsensing framework for traffic violation hotspot patrolling,” *IEEE Transactions on Mobile Computing*, 2021.
- [7] L.-W. Chen, Y.-C. Tseng, and K.-Z. Syue, “Surveillance on-the-road: Vehicular tracking and reporting by v2v communications,” *Computer Networks*, vol. 67, pp. 154–163, 2014.
- [8] S. Bouchelaghem and M. Omar, “Reliable and secure distributed smart road pricing system for smart cities,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 20, no. 5, pp. 1592–1603, 2018.
- [9] Z. Ma, M. Jiang, and W. Huang, “Trusted forensics scheme based on digital watermark algorithm in intelligent vanet,” *Neural Computing and Applications*, vol. 32, no. 6, pp. 1665–1678, 2020.
- [10] R. Hussain, D. Kim, J. Son, J. Lee, C. A. Kerrache, A. Benslimane, and H. Oh, “Secure and privacy-aware incentives-based witness service in social internet of vehicles clouds,” *IEEE Internet of Things Journal*, vol. 5, no. 4, pp. 2441–2448, 2018.
- [11] C. Anglès-Tafalla, A. Viejo, J. Castellà-Roca, M. Mut-Puigserver, and M. M. Payeras-Capellà, “Security and privacy in a blockchain-powered access control system for low emission zones,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 24, no. 1, pp. 580–595, 2023.
- [12] C. Anglès-Tafalla, A. Viejo, R. Trujillo-Rasua, and J. Castellà-Roca, “From panoptic to secure and privacy-preserving lateral surveillance in vehicle restricted areas,” *IEEE Transactions on Intelligent Transportation Systems*, 2025.
- [13] E. I. Delivered, “The trl scale as a research & innovation policy tool, earto recommendations,” *Earto Impact Delivered*, 2014.

Causal Digital Twins for Cyber-Physical Security in Water Systems: A Framework for Robust Anomaly Detection

Mohammadhossein Homaei
Grupo de Ingeniería de Medios
Universidad de Extremadura,
Cáceres, Spain
mhomaein@alumnos.unex.es

Mehran Tarif
Department of Computer Science
University of Verona, Verona, Italy
mehran.tarifhokmabadi@univr.it

Pablo García Rodríguez, Andrés Caro, Mar Ávila
Grupo de Ingeniería de Medios
Universidad de Extremadura,
Cáceres, Spain
{pablogr, andresc, mmavila}@unex.es

Abstract—Industrial Control Systems (ICS) in water infrastructures are increasingly vulnerable to cyber-physical attacks that exploit both network and physical process vulnerabilities. Current anomaly detection methods rely on statistical correlations, resulting in high false alarm rates and inadequate root cause analysis. We propose a novel Causal Digital Twin (CDT) framework that integrates causal inference with digital twin modeling for water system security. The framework enables three levels of causal reasoning: association for pattern detection, intervention for system response prediction, and counterfactual analysis for attack prevention. Evaluated on SWaT, WADI, and HAI datasets, CDT demonstrates high compliance with physical constraints (90.8% for SWaT) and achieves F1-scores of 0.944 ± 0.014 (SWaT), 0.902 ± 0.021 (WADI), and 0.923 ± 0.018 (HAI). Multi-scale temporal detection strategies enable 91.7% detection of stealthy attacks. CDT reduces false positives by 48% compared to state-of-the-art methods, achieves 78.4% root cause accuracy, and enables counterfactual defenses reducing attack success by up to 89.1%, with real-time performance at 3.2 ms latency, supporting operational deployment in SCADA environments.

Index Terms—Causal inference, Digital twin, Industrial control systems, Cyber-physical security, Anomaly detection, Water systems

Tipo de contribución: Investigación ya publicada (límite 2 páginas)

I. INTRODUCTION AND MOTIVATION

The combination of operational technology and information technology within Industrial Control Systems has introduced significant cybersecurity risks. Water treatment infrastructures, such as the SWaT testbed, which contains 51 sensors and actuators distributed across six operational phases, are increasingly exposed to complex cyber-physical threats that cannot be effectively handled by conventional correlation-based detection techniques.

Conventional anomaly detection methods are limited by three main issues: (1) elevated false positive rates resulting from the inability to separate causal dependencies from simple statistical associations, (2) weak capabilities in identifying attack origins and tracking their spread across system components, and (3) the absence of counterfactual analysis for supporting preventive security strategies. For instance, statistical correlation may reveal dependence between pressure and flow measurements; however, such relationships may arise from shared environmental or operational factors rather than




Fig. 1. Overview of the proposed CDT framework

direct physical causation, a phenomenon related to Simpson's paradox.

To address these limitations, we propose a Causal Digital Twin framework that emphasizes causal modeling rather than pure statistical similarity. This framework enables reasoning about intervention scenarios, such as evaluating system behavior after activating protective mechanisms, as well as counterfactual analysis to assess whether an attack would remain successful after eliminating system vulnerabilities.

II. PROPOSED CDT FRAMEWORK

The framework follows Pearl's Causal Hierarchy and consists of four phases, as shown in Fig. 1.

Phase I: Decoupled Causal Discovery. To reduce the high computational cost of causal discovery, we use a two-step process. First, Time-Delay Mutual Information is used to find possible causal links and shrink the search space to about $k \leq 10$ variables per node. Then the PC algorithm is applied with domain knowledge constraints such as temporal order, physical laws, and system control logic. This reduces complexity to $O(n \cdot k^3)$.

Phase II: Structural Causal Model Estimation. Structural equations are learned using additive noise models for continuous variables and logistic models for binary actuator signals.

Model parameters are estimated using maximum likelihood. Performance is evaluated using 10-fold cross-validation, giving $R^2 = 0.892 \pm 0.023$ on the SWaT dataset, along with testing on real operational data.

Phase III: Interventional Digital Twin. We use do-calculus to estimate interventional distributions $P(Y|do(X = x))$ using backdoor and frontdoor adjustment. This helps predict system responses under defense actions while reducing the effect of confounding variables.

Phase IV: Real-Time Causal Monitoring. For monitoring, observed sensor values are compared with causal predictions $E[V_i|do(PA(V_i) = pa_i(t))]$. Instead of only finding statistical anomalies, the method tries to detect mechanism-level failures. Root cause analysis is performed using Shapley causal values, while counterfactual reasoning supports what-if planning for security.

TABLE I
COMPARISON WITH STATE-OF-THE-ART ICS SECURITY APPROACHES

Method	Main Limitation	Explainability	Reasoning
CNN-1D	Black-box	None	Correlation
PbNN	Correlation-based	Limited	Physics only
ICS-CAD	Network-level only	High	Network causal
CDT	Complexity	Complete	Interventional+Counterfactual

III. EXPERIMENTAL VALIDATION

We evaluated the framework on three industrial datasets: SWaT (51 variables, 41 attacks), WADI (123 variables, 15 attacks), and HAI (78 variables, 28 attacks). Table II summarizes detection performance compared to seven baseline methods.

TABLE II
DETAILED DETECTION PERFORMANCE ACROSS ALL DATASETS

Dataset	Method	Precision	Recall	F1-Score
SWaT	CNN-1D	0.823	0.861	0.841
	InterFusion	0.898	0.916	0.907
	ICS-CAD	0.921	0.935	0.928
	CDT (Ours)	0.947	0.941	0.944
WADI	CNN-1D	0.756	0.798	0.776
	InterFusion	0.834	0.867	0.850
	ICS-CAD	0.851	0.874	0.862
	CDT (Ours)	0.893	0.912	0.902
HAI	CNN-1D	0.781	0.823	0.801
	InterFusion	0.856	0.889	0.872
	ICS-CAD	0.875	0.901	0.888
	CDT (Ours)	0.916	0.931	0.923

Key findings include:

Causal Structure Quality: Discovered graphs achieve $90.8\% \pm 3.2\%$ compliance with physical constraints for SWaT, with structural Hamming distance 0.133 ± 0.02 on synthetic validation datasets with known ground truth.

Detection Performance: CDT achieves statistically significant improvements ($p < 0.0024$, Bonferroni corrected) across all datasets with F1-scores of 0.944 ± 0.014 (SWaT), 0.902 ± 0.021 (WADI), and 0.923 ± 0.018 (HAI). False positive rate reduction reaches 48% compared to state-of-the-art (70% vs. statistical baselines), attributed to mechanism-based detection rather than statistical deviation detection.

Attack-Specific Performance: CDT demonstrates robustness across all attack categories (Table III). Notably, stealthy

attacks with slow drift rates (≈ 0.002 units/s) achieve 91.7% detection using multi-scale temporal analysis, while physical process attacks reach perfect detection (100%) through causal mechanism violations.

TABLE III
DETECTION RATE BY ATTACK TYPE (SWaT)

Attack Type	Count	CDT	Best Baseline
Single-point	18	97.2%	95.1%
Multi-point	12	91.7%	87.3%
Stealthy	6	91.7%	83.3%
Physical	3	100%	92.8%
Overall	41	94.4%	90.7%

Root Cause Analysis: CDT achieves $78.4\% \pm 3.8\%$ Top-1 accuracy in identifying attack sources, representing 29.7% improvement over the best attribution baseline (Integrated Gradients at 48.7%). For complex multi-stage attacks, the framework successfully traces full causal cascades with 94.3% accuracy.

Counterfactual Defense Planning: Analysis of defense strategies across 84 attack scenarios identifies optimal mitigations. Causal anomaly detection as a defense mechanism prevents 37/41 SWaT attacks (89.1% success rate reduction), outperforming network segmentation (58.3%) and redundant control logic (67.9%).

Computational Feasibility: Real-time components achieve 3.2ms latency for anomaly detection and 12.7ms for root cause analysis, meeting industrial control loop requirements (100-1000ms SCADA cycles). Offline causal discovery requires 23.4min for the 51-variable SWaT system.

IV. CONCLUSIONS AND FUTURE WORK

This work introduces interventional and counterfactual causal reasoning into digital twins for ICS security, with direct applicability to operational water infrastructure deployments. The CDT framework shows that using explicit causal models instead of correlation improves detection accuracy, lowers false positives, and gives more useful security insights. The model assumes causal sufficiency, and hidden confounders such as ambient temperature can reduce the F1-score by about 3.2%. Stealth attack detection (91.7%) is lower than abrupt attack detection (97.2%) and may be close to the theoretical limit with limited data. Also, systems with more than 500 variables need distributed methods for scalability.

Future work includes distributed causal discovery for large systems, recurrent causal learning with temporal windows to handle equipment changes, improved stealth detection using Bayesian change-point methods, and standard SCADA interfaces for sharing causal models across industrial systems.

ACKNOWLEDGEMENT

This activity has been co-financed 85% by the European Union, the European Regional Development Fund and the Regional Government of Extremadura. Managing Authority: Ministry of Finance. Grant File Number: GR24170.

REFERENCES

- [1] M. Homaei, M. Tarif, P. García Rodríguez, A. Caro, and M. Ávila, "Causal Digital Twins for cyber-physical security in water systems: A framework for robust anomaly detection," *Machine Learning with Applications*, vol. 23, p. 100824, 2026. DOI: 10.1016/j.mlwa.2025.100824

Self-Sovereign Digital Identity: a construction from Barreto et al. ID-based signatures

María Isabel González Vasco

Universidad Carlos III de Madrid

Dpto. de Matemáticas

mariaisabel.gonzalez@uc3m.es

Vicente Muñoz

Universidad Complutense de Madrid

Dpto. Álgebra, Geometría y Topología

vicente.munoz@ucm.es

Angel Pérez del Pozo

Universidad Rey Juan Carlos

Dpto. MACIMTE

angel.perez@urjc.es

Claudio Soriente

GMV

csoriente@gmv.com

Abstract—We present a distributed private key generation architecture as a fundamental component of a self-sovereign identity (SSI) framework. Our design enables users to securely obtain identity-based signing keys through an authenticated enrollment process while retaining exclusive control over their final secret keys. To address the key escrow problem inherent in identity-based cryptography, private keys are generated collaboratively by multiple independent hardware security modules coordinated by a central node. The construction is tailored to the Barreto et al. identity-based signature scheme and avoids requiring users to perform share recombination or complex cryptographic operations. Targeting the honest-but-curious adversarial model, our approach deliberately favors simplicity over heavyweight cryptographic techniques, resulting in a practical and deployable solution suitable for real-world SSI systems.

Index Terms—ID-based cryptography, Signature Schemes, Distributed Key Generation.

Tipo de contribución: *Transferencia (límite 4 páginas)*

I. INTRO

Digital identity has been studied since the early days of the digital era and today encompasses a broad range of mechanisms for identifying individuals and organizations during service provision. Self-Sovereign Identity (SSI) is a more recent identity-management paradigm that gives users direct control over their credentials, with the goal of improving privacy and reducing reliance on centralized identity providers.

In this note, we describe and analyze GMV's Self-Sovereign Identity (SSI) framework. [1] Our construction is identity-based and therefore avoids reliance on a certificate-based Public Key Infrastructure (PKI). To mitigate the key-escrow problem inherent to identity-based cryptography, private keys are generated in a distributed manner using three independent Hardware Security Modules (HSMs), orchestrated by (and communicating through) a KG.Coordinator node.

In our design, users interact with the SSI manager, which acts as an intermediary between the KG.Coordinator and the end user requesting a private key for signing. The system leverages an identification mechanism (for example, biometrics) to authenticate users and, upon successful verification, associates them with an identity through an enrollment process. Once enrolled, a user may submit a request and receive a masked private key. This key can only be unmasked by the user, allowing them to derive the final secret key, which they securely store in the wallet for future use. Compared with traditional PKI-based systems, identity-based cryptography offers the advantage of simplified public key identification. However, it suffers from a major limitation: the key escrow problem. Over the years, this issue has been addressed through




Fig. 1. Functional Model of the SSI platform

various approaches, most of which aim to distribute the key generation process among multiple authorities. This paper follows such a strategy. In particular our design is tailored to the key generation mechanism proposed by Sakai and Kasahara in [2]. It can be used as the key generation algorithm of an identity-based digital signature scheme, such as the one proposed by Barreto et al. [3], which is the signature scheme of choice in the GMV framework [1].

A. Related work

Our construction can be viewed as a design for a *Key Distribution Center* for the Barreto et al. signature scheme, in the spirit of Geisel and Smart [4]. In that work, the authors propose a distributed key generation method for identity-based encryption with the goal of distributing trust among multiple servers¹. However, Geisel and Smart approach requires users to actively recombine the shares received from the servers in order to reconstruct their private key, which limits its practical applicability. By contrast, in our construction the reconstruction is handled by a partially trusted coordinator (assumed honest-but-curious), which computes a masked secret key from the servers' shares. The user only needs to perform a lightweight unmasking step.

In the encryption setting, Kate and Goldberg [5] extend this idea by proposing distributed versions of several identity-based schemes. Their construction strengthens the adversarial

¹It is worth remarking that the method for obtaining private keys from identities in Barreto et al.'s scheme is a simplification of a method suggested by Sakai and Kasahara (see [2])

model—covering Byzantine faults—while maintaining comparable complexity. Nevertheless, as in [4], users must locally combine key shares to obtain their private key.

More closely related to our approach, Feng et al. [6] present a distributed key generation protocol where servers execute the reconstruction phase, so the user retrieves the secret key with minimal computation. Their scheme achieves security in the universal composability framework under a strong adversarial model, but relies on advanced tools such as commitments and zero-knowledge proofs. Our work can be seen as a streamlined variant of this construction, retaining only the mechanisms required for security in the honest-but-curious model, thereby yielding a simpler and more practical design for implementation and auditing.

II. MODEL

A. Involved entities

a) *User*: End entity that will consume the authentication and cryptographic services provided by the system. It owns a concrete physical device that is fully under his/her control and is able to interact with the SSIManager through a private and authenticated channel.

b) *SSI Management Unit*:

- SSIManager. It both communicates with users and with the KG.Coordinator through private and authenticated channels. In addition, it has access to a database where all information on users identities is stored (IDDB).
- Notary. HSM where all private keys needed by the SSIManager are securely stored.

c) *Key Generator*:

- KG.Coordinator. It communicates both with the SSIManager and the Generators through private and authenticated channels. It has access to a Preprocessed Tuples Database (PTDB) where some auxiliary data needed for key computation is stored.
- Generators. Independent HSM modules, each connected through the KG.Coordinator with a private and authenticated channel. Thus, the Generators can only share information among themselves through the KG.Coordinator.

B. High level description

The signing mechanism of choice in our design is an identity-based signature scheme as depicted by Barreto et al. In this scheme, given a public point P and a hash function H the secret key corresponding to an identity Id is constructed as the multiple $\frac{1}{s+H(Id)}P$ of the public point P . In our design, the secret master key s should be constructed in a distributed manner in order to limit the ability of a single entity to influence solely the key generation.

This is attained through the implementation of an *Distributed PKG for an Identity Based Signature Scheme* that can be defined (in style following [5]) as consisting of the following components:

- *Enrollment*. The user identifies himself to the SSIManager (biometrically or by document validation) and gets linked to an identifier Id .
- *Distributed Setup Protocol*. This is a trusted phase in which all selected parameters are publicized. Select an elliptic curve E , a point P from E generating a group

G of prime order q (within the natural additive group structure defined over E), a bilinear map $e : G \times G \rightarrow G'$, to some known group G' of order q .

The Generators and KG.Coordinator jointly generate a master secret key s and publicize the corresponding master public key sP . They do so in a distributed manner, following a specific strategy (see Section III), that in particular allows them to store shares of s that will be used upon users' requests to reconstruct the corresponding private keys.

- *Distributed private key-extraction protocol for a user*. To request the construction of its private signing key, a user computes a masked point P' (which is just a multiple rP , for some r selected uniformly at random by the user) and forwards to the KG.Coordinator a private key request message containing all public parameters, the point P' and a public identifier Id .

The KG.Coordinator will then forward a request to each Generator node, which will thus perform computations and respond with a share of the corresponding masked user's key for the requested identity. The actual value of this masked key $(s+H(Id))^{-1}P'$ is reconstructed by the KG.Coordinator and forwarded to the requesting user.

Finally, the user unmaskes (using r) the received value to retrieve his actual private key $SK_{Id} = (s+H(Id))^{-1}P$, which is only accepted after checking its consistency (using knowledge of P, sP and $H(Id)$), by means of the algebraic pairing e , i.e., the key is accepted if and only if

$$e(P, P) = e(SK_{Id}, sP + H(Id)P).$$

The idea of masking the key request and unmasking the key after reception is used in other similar constructions, for instance [6].

III. DISTRIBUTED GENERATION OF s AND BEAVER TRIPLES IN THE DISTRIBUTED SETUP PROTOCOL

Let G_i denote Generator number i for $i = 1, 2, 3$. In the *Setup* phase, each G_i selects uniformly at random $s_i \in \mathbb{Z}_q$ and computes and makes public s_iP . The master secret key s is set as $s = s_1 + s_2 + s_3$ (although it is never explicitly computed). Note that any entity is able to compute sP as $s_1P + s_2P + s_3P$.

Additionally, a specified number of so-called Beaver triples are jointly computed among the three Generators. For each triple computation, Generator G_i ends up with a private output $t_i = (a_i, b_i, c_i)$. These values satisfy the following equality:

$$(a_1 + a_2 + a_3)(b_1 + b_2 + b_3) = c_1 + c_2 + c_3.$$

and are typically referred to as *Beaver triples* or *multiplication triples*. We do not describe the generation of these triples here; it can be found in [1].

Once a triple is obtained, each G_i computes an associated auxiliary value $\mu_i = s_i - b_i$. Then it handles this value μ_i together with an encryption $\text{Enc}(t_i)$ of t_i to the KG.Coordinator. In turn, the coordinator computes $\mu = \mu_1 + \mu_2 + \mu_3$ and stores it together with the encryptions of t_1, t_2, t_3 . This process is executed for all the required triples.

IV. DISTRIBUTED PRIVATE KEY-EXTRACTION PROTOCOL FOR A USER

Now we will describe the private key generation algorithm for a user with identity Id :

- 1) The user selects a value $r \in \mathbb{Z}_q$ uniformly at random and computes a masked point $P' = rP$.
- 2) The user sends a private key generation request (Id, P') to the KG.Coordinator through the SSIManager.
- 3) The KG.Coordinator selects a Beaver triple record $(\mu, \text{Enc}(t_1), \text{Enc}(t_2), \text{Enc}(t_3))$ from its database.
- 4) For each $i = 1, 2, 3$, the KG.Coordinator sends $(Id, P', \mu, \text{Enc}(t_i))$ to Generator G_i .
- 5) Each Generator G_i decrypts $\text{Enc}(t_i)$ to obtain $t_i = (a_i, b_i, c_i)$. Then it computes the value

$$v_i = c_i + a_i(\mu + H(Id)),$$

and a point $P'_i = a_i P'$.

- 6) Each Generator G_i sends (v_i, P'_i) to the KG.Coordinator.
- 7) The KG.Coordinator computes the masked secret key for the user as $\overline{SK}_{Id} = (v_1 + v_2 + v_3)^{-1}(P'_1 + P'_2 + P'_3)$.
- 8) The KG.Coordinator sends $\overline{SK}_{Id}$ to the user through the SSIManager.
- 9) The user computes the secret key as $SK_{Id} = r^{-1} \overline{SK}_{Id}$.
- 10) The user checks whether

$$e(P, P) = e(SK_{Id}, sP + H(Id)P),$$

and accepts the key if and only if the equality holds.

A. Correctness of key computation

Let us show that, when the protocol specification is followed, $SK_{Id} = (s + H(Id))^{-1}P$ as expected.

Let $a = a_1 + a_2 + a_3$, $b = b_1 + b_2 + b_3$ and $c = c_1 + c_2 + c_3$. Recall that the Beaver triple construction ensures that $ab = c$. Additionally, note that $\mu = \mu_1 + \mu_2 + \mu_3 = s - b$.

First let us compute the value

$$\begin{aligned} v_1 + v_2 + v_3 &= \sum_{i=1}^3 (c_i + a_i(\mu + H(Id))) = \\ &= c + a(\mu + H(Id)) = c + as - ab + aH(Id) = a(s + H(Id)). \end{aligned}$$

Therefore we have

$$\begin{aligned} SK_{Id} &= r^{-1} \overline{SK}_{Id} = r^{-1}(v_1 + v_2 + v_3)^{-1}(P'_1 + P'_2 + P'_3) = \\ &= r^{-1}(a(s + H(Id)))^{-1}aP' = (s + H(Id))^{-1}P, \end{aligned}$$

as required.

Finally, note that the check

$$\begin{aligned} e(SK_{Id}, sP + H(Id)P) &= \\ &= e((s + H(Id))^{-1}P, (s + H(Id))P) = e(P, P) \end{aligned}$$

holds.

V. ASSUMPTIONS AND SECURITY GOALS

We list different assumptions to formally describe the constraints under which our design can be proven secure.

- Setup assumptions: We may assume that all entities behave honestly during the setup phase. Furthermore, we can in addition assume that some system parameters (e.g., the master public key) are securely transmitted from a trusted authority during the setup phase and can be securely stored by each user.
- Network assumptions: for our application scenario, we may assume that all parties can communicate synchronously and there will be no crashes or link failures. As depicted in Figure 1 we will assume that confidential and authenticated channels are available connecting:
 - each user with the SSIManager
 - the SSIManager and the KG.Coordinator
 - each Generator and the KG.Coordinator
- Adversarial behavior assumptions: we assume that adversaries are probabilistic polynomial time machines and that all parties are honest-but-curious (HBC), i.e., they follow the protocol specification faithfully. As will be made clear in the next section, we do not exclude collusions in this setting; i.e., entities that follow the protocol specification may share information in order to maximize their knowledge of secret values or parameters. The configurations of such collusions are the key point in our security analysis.
- Cryptographic assumptions: Our protocol distributes the generation of signature keys and, as in [4], aims to show that the resulting keys are as secure as those from the original (non-distributed) construction. When this holds, security matches that of Barreto et al. signatures, which rely on the hardness of a *Bilinear Diffie Hellman Inversion problem* (see [3]).

Once the assumptions taken are made explicit, it is necessary to define accurately the security guarantees we are aiming at. We, of course, start by giving a definition for correctness.

a) *Correctness*: Assuming no adversarial action, the secret key a user gets as private output is correct, i.e., the user can, through the signing algorithm, produce signatures that will be validated with the corresponding public key.

In order to evaluate the security, we will follow the rationale from Geisler and Smart (see [4]), where, assuming the original signature scheme is secure, we define the security of a distributed key generation process by stating that keys generated using this protocol are indistinguishable from keys generated as in the original (not distributed) signature scheme.

b) *Security*: Assuming that all entities involved in the key generation process follow the protocol specification faithfully, i.e., assuming we work in the so-called *honest-but-curious* (or HBC) scenario, and under all network and cryptographic assumptions taken, no probabilistic polynomial time adversary can distinguish, except with negligible probability, between a secret key output by the system for a certain user Id and a secret key generated following the (standard, not distributed) IBE signature specification. Obviously, a coalition of the three generators is able to recover s and compute any secret key. We thus need to consider that the HBC scenario in

our case considers “curious collusions”, in the sense that we state security guaranteeing that any coalition of entities (which share information, but follow the protocol specification) in which the three generators are not present will not be able to obtain any information about a user’s secret key.

VI. SECURITY ANALYSIS

In this section, we informally analyze the security of the scheme following again the rationale and style of [4].

Correctness. We assume that the Setup phase is correct, and thus, in particular, the distributed generation of the secret s and of the Beaver triples is correctly carried over. Note that the master secret key s is implicitly constructed as $s = s_1 + s_2 + s_3$, where each value s_i is independently and uniformly sampled from $\mathbb{Z}_q$ by G_i . Thus, the resulting value s remains uniformly distributed over $\mathbb{Z}_q$. As a result the public key and secret keys are computed in the same way as in the original scheme. The correctness of the latter therefore carries over and guarantees the correctness of our construction (as depicted in Section IV-A).

Security. Assume, without loss of generality, that the KG.Coordinator and generators G_1 and G_2 form a coalition—which, while following faithfully the protocol specification, may share information in order to gain knowledge about the derived secret keys.

Notice that the KG.Coordinator has access to the values $\mu_i = s_i - b_i$. But b_3 is part of the Beaver triple t_3 corresponding to G_3 and unknown to the coalition, as it is sent to the KG.Coordinator encrypted. Consequently, the share s_3 is completely hidden to the coalition and, therefore, it has the same information about the master secret key $s = s_1 + s_2 + s_3$ as an external adversary.

Furthermore, note that the masked secret key $\overline{SK}_{Id}$ computed by the KG.Coordinator equals rSK_{Id} , where r is the masking value chosen by the user. Therefore the coalition gets no information about the secret key from $\overline{SK}_{Id}$.

All in all, we can argue that the view of the coalition is the same as the view of an external adversary against the original Barreto et al. scheme security in our construction follows from the standard security of this signature scheme.

VII. ADDITIONAL CONSIDERATIONS

We discuss a few possible extensions of our protocol, aiming at some advanced security goals that may be of interest for concrete application scenarios.

Security - Malicious scenario. In our analysis, we assume that all entities behave honestly but curiously throughout the entire execution of the protocol. Nevertheless, it may be reasonable to restrict this assumption to an honest setup phase and to subsequently analyze our construction under the assumption that all entities participating in the key generation process adhere to the protocol specification, with the exception of at most a coalition of entities that never includes the three generator nodes. To this end, we would need to prove that, during the private key extraction protocol (depicted in Section IV), any deviation from the protocol specification occurring in Steps 3 through 8 necessarily results in an abort by the user in Step 10. It is possible that achieving this

goal requires only minimal—or even no—modifications to our scheme, which we leave for future work.

Privacy. User privacy was not an objective in the original design of the presented protocol. Users submit a public identifier Id to the KG.Coordinator, which is also forwarded to each Generator. An external access control mechanism is assumed to verify that the request corresponds to a legitimate user associated with that identifier. In some application scenarios, however, privacy and non-traceability may be desirable. Instead of transmitting Id , users could present a non-identifying token, provided that an appropriate authentication mechanism enforces access control while preserving privacy. Informally, privacy would ensure that no probabilistic polynomial-time adversary can distinguish the interaction of a specific user from that of a random one, except with negligible probability. Untraceability would further require that an adversary cannot determine whether two protocol executions involve the same user. Assuming a trusted KG.Coordinator and a system with n Generators, it is therefore natural to investigate whether a threshold variant of the GMV protocol (with $t \leq n$ honest Generators) can achieve such properties.

ACKNOWLEDGEMENTS

This research was conducted within GMV’s Project “Identidad Digital Soberana” and has been partially funded by the Instituto Nacional de Ciberseguridad (INCIBE) through resources from the Spanish “Plan de Recuperación, Transformación y Resiliencia” (PRTR), funded by the European Union’s Recovery and Resilience Facility, Fondos NextGeneration-EU. The project was carried out within the framework of the initiative “Iniciativa Estratégica de Compra Pública de Innovación (IECPI)”, which aims to promote innovation and competitiveness in cybersecurity by supporting R&D and the development of high value-added solutions, products, and services through public procurement.

The security analysis contained herein pertains to a method that has been previously disclosed in the public patent application [1]. The opinions expressed in this publication are those of the author(s) and do not necessarily reflect those of the co-financing entity.

REFERENCES

- [1] J. J. León Cobos and P. Celis De La Hoz, “Method and entity for generating a private key in an identity-based cryptosystem without key escrow,” Patent WO2024017913A1, 2024.
- [2] R. Sakai and M. Kasahara, “ID based cryptosystems with pairing on elliptic curve,” *Cryptology ePrint Archive*, Paper 2003/054, 2003. [Online]. Available: <https://eprint.iacr.org/2003/054>
- [3] P. S. L. M. Barreto, B. Libert, N. McCullagh, and J. Quisquater, “Efficient and provably-secure identity-based signatures and signcryption from bilinear maps,” in *ASIACRYPT 2005*, ser. LNCS, vol. 3788. Springer, 2005, pp. 515–532.
- [4] M. Geisler and N. Smart, “Distributing the key distribution centre in sakai-kasahara based systems,” in *Cryptography and Coding*. Springer, 2009, pp. 252–262.
- [5] A. Kate and I. Goldberg, “Distributed private-key generators for identity-based cryptography,” in *SCN 2010*, ser. LNCS, vol. 6280. Springer, 2010, pp. 436–453.
- [6] Q. Feng, D. He, H. Wang, D. Wang, and X. Huang, “Multi-party key generation protocol for the identity-based signature scheme in the IEEE P1363 standard for public key cryptography,” *IET Information Security*, vol. 14, no. 6, pp. 724–732, 2020.

Sesión de Investigación 3 - Escenarios y plataformas I

Optimising secure and sustainable smart home configurations

Daniel Muñoz Heredia

IDEA Research Group - Universidad de Sevilla
Orcid:0009-0000-1935-7550
dmunnoz@us.es

Ángel Jesús Varela-Vaca

IDEA Research Group - Universidad de Sevilla
Orcid:0000-0001-9953-6005
ajvarela@us.es

Diana Borrego

IDEA Research Group - Universidad de Sevilla
Orcid:0000-0002-7471-9208
dianabn@us.es

María Teresa Gómez-López

IDEA Research Group - Universidad de Sevilla
Orcid:0000-0002-3562-875X
maytegonomez@us.es

Abstract—As the adoption of devices accelerates rapidly in smart homes worldwide, the variety of available devices on the market is also diversifying. This creates a challenge for users, who must choose devices that best meet their needs, and for system designers, who must ensure these devices integrate efficiently within a connected ecosystem. In response to this challenge, the solution presented in this work provides a metamodel that gathers the smart home features, including attributes related to security, usability, connectivity and sustainability. These features are used to create configurations of smart homes that meet user requirements. This is achieved through the creation of multi-objective optimisation problems focused on improving: security, to ensure network and personal data protection; usability, to facilitate the easy management of the environment; connectivity, to maintain seamless interaction between both existing and future devices; and sustainability, which assesses the environmental impact and energy efficiency of the technological ecosystem.

Index Terms—Smart homes, Multi-objective problems, Security, Usability, Connectivity, Sustainability

Tipo de contribución: *Investigación ya publicada - Internet of Things*, vol. 32, 2025. DOI: 10.1016/j.iot.2025.101637.

SUMMARY OF THE CONTRIBUTION

We propose ALBA-Assistant as a solution to address the growing complexity of device selection and smart home configuration design. ALBA-Assistant is a decision-support framework that produces optimised Smart Home configurations according to user requirements. The proposal is grounded on a tailored metamodel that unifies attributes related to security, usability, connectivity and sustainability, extending CARMEN [1] and Onto-CARMEN [2] by incorporating specific elements that are useful to model smart devices and their relevant properties in the areas to be optimised.

User preferences are obtained through two main dimensions: the number of devices per category that the final configuration must include and the level of importance assigned to each objective (NONE, LOW, MEDIUM, HIGH or VERY HIGH). Based on these requirements, ALBA-Assistant automatically formulates a Constraint Optimisation Problem (COP) and solves it with a constraint programming engine to obtain the optimal configuration for one or multiple objectives (Fig. 1).

In terms of security, the system integrates CVE [3] data to minimise the overall impact (based on CVSS [4] severity) and to reduce the diversity of weaknesses (CWE [5]) present

in the configuration. In usability, it minimises the number of applications required to manage all devices in the smart home. For connectivity, it maximises the number of communication technologies available in the configuration, promoting interoperability. Finally, for sustainability, it maximises a score computed from device attributes related to the power supply and computational capability.

PROBLEM FORMULATION AND OPTIMISATION

Device selection is represented by boolean variables $devices[i] \in \{0, 1\}$ for each device i in the dataset, indicating whether the device is excluded or included. Based on these binary decisions, ALBA-Assistant automatically generates a Constraint Optimisation Problem (COP), which is solved by a constraint programming engine to obtain a possible configuration.

The solver evaluates four objective scores, corresponding to the optimisation dimensions considered in this work:

- **Security** (S_{sec}): minimise two equally weighted sub-metrics, the total impact derived from CVSS values and the number of distinct CWEs present in the current configuration.
- **Sustainability** (S_{sus}): maximise an aggregated sustainability value computed from individual device scores, with 75% of each score derived from power supply attributes and 25% from computational capability.
- **Connectivity** (S_{conn}): maximise the number of distinct connectivity technologies available in the current configuration.
- **Usability** (S_{usa}): minimise the number of different management apps required to operate the selected devices.

For multi-criteria optimisation, user preferences are expressed as qualitative importance levels (NONE, LOW, MEDIUM, HIGH, VERY HIGH), mapped to $\{0, 0.25, 0.50, 0.75, 1\}$ and normalised into W_i to weight the objectives in a single minimisation function (Eq. (1)), with connectivity and sustainability scores negated to convert inherently maximising objectives into equivalent minimisation terms.

$$\min \left(W_{sec} S_{sec} - W_{conn} S_{conn} - W_{sus} S_{sus} + W_{usa} S_{usa} \right) \quad (1)$$




Fig. 1. ALBA-Assistant process overview.

DEVICE DATASET AND EXPERIMENTAL SETUP

ALBA-Assistant natively provides 425 unique devices organised into 23 categories, selected mainly from the CIC IoT Dataset 2023 [6] and enriched with additional characteristics extracted from official manufacturer documentation, so that the generated configurations are replicable in real-world scenarios. The modelling explicitly incorporates terminology and criteria aligned with ENISA and, for security-related properties, it relies on NIST services to keep the data accurate and up to date.

To demonstrate the feasibility of the proposed solution, six experiments are conducted. The first phase (Experiments 1-5) assesses the scalability of ALBA-Assistant by measuring the response times required to solve the COP. In this phase, performance is analysed when optimising each objective in isolation (security, sustainability, connectivity or usability) as well as in the multi-objective case, varying both the dataset size (from 125 to 425 devices) and the number of devices requested in the configuration. The second phase (Experiment 6) studies the system behaviour under partial configurations, the user imposes a set of mandatory devices that must appear in the final solution and ALBA-Assistant automatically completes the rest of the configuration by selecting devices from the dataset that best satisfy the established objectives.

EXPERIMENTAL RESULTS

Response times increase as the number of requested devices and dataset size grow, following a non-linear trend as the search space expands. For configurations of 20 devices on the full dataset (425 devices), the average response time is 0.484 s for security, 0.0756 s for sustainability, 0.202 s for connectivity and 0.157 s for usability, whereas the multi-objective case achieves an average response time of 0.643 s. Since 20 devices closely approximate the average smart home size (21) reported by Deloitte (2023) [7], these sub-second response times confirm the practical viability of ALBA-Assistant in real-world deployment scenarios.

For partial configurations, when no mandatory devices are imposed, the final solution achieves an average impact of 0 with an empty CWE set, a sustainability value of 5.35, 9 connectivity technologies and only one required app. When all 15 devices are imposed, the results degrade to an average impact of 3.561, 20 CWEs, a sustainability value of 4.95, 7 connectivity technologies and 3 required apps, illustrating how mandatory device constraints can reduce the achievable optimisation quality while also highlighting the system's ca-

capacity to complement existing devices with optimal selections from the dataset.

CONCLUSIONS

ALBA-Assistant is presented as a solution that enables users with no knowledge of IoT devices to create a smart home configuration according to their requirements, thanks to a controlled multi-objective optimisation solver using constraint optimisation problems. The proposal extends an existing metamodel to include properties related to security, sustainability, connectivity and usability. The applicability of the proposal is demonstrated through a set of experiments. In addition to the returned devices, the solution provides a range of general values related to the optimised objectives, allowing the user to compare and adjust the obtained solutions. Furthermore, it is important to emphasise how the use of constraint optimisation problems (COP) lets us model complex problems that are solved in a feasible time. These problems tend to be complex due to the large number of variables and constraints that must be considered simultaneously. Efficiently solving a COP requires robust algorithms and often involves a trade-off between processing time and result accuracy. Moreover, as the scale of devices and constraints increases, COPs become progressively more challenging, as evidenced by the experiments conducted, which negatively affect both the computational performance and the quality of the solutions obtained.

REFERENCES

- [1] Á. J. Varela-Vaca, D. G. Rosado, L. E. Sánchez, M. T. Gómez-López, R. M. Gasca, and E. Fernández-Medina, "Carmen: A framework for the verification and diagnosis of the specification of security requirements in cyber-physical systems," *Computers in Industry*, vol. 132, 2021. [Online]. Available: <https://doi.org/10.1016/j.compind.2021.103524>
- [2] C. Blanco, D. G. Rosado, Á. J. Varela-Vaca, M. T. Gómez-López, and E. Fernández-Medina, "Onto-carmen: Ontology-driven approach for cyber-physical system security requirements meta-modelling and reasoning," *Internet of Things*, vol. 24, 2023. [Online]. Available: <https://doi.org/10.1016/j.iot.2023.100989>
- [3] MITRE, "Common Vulnerabilities and Exposures," 2026, accessed 20 February 2026. [Online]. Available: <http://cve.mitre.org/>
- [4] FIRST, "Common Vulnerability Scoring System SIG," 2026, accessed 20 February 2026. [Online]. Available: <https://www.first.org/cvss/>
- [5] MITRE, "Common Weakness Enumeration," 2026, accessed 20 February 2026. [Online]. Available: <http://cwe.mitre.org/index.html>
- [6] E. C. P. Neto, S. Dadkhah, R. Ferreira, A. Zohourian, R. Lu, and A. A. Ghorbani, "Ciciot2023: A real-time dataset and benchmark for large-scale attacks in iot environments," *J. Sensors*, 2023. [Online]. Available: <https://www.mdpi.com/1424-8220/23/13/5941>
- [7] Jana Arbanas and Paul H. Silvergate and Susanne Hupfer and Jeff Loucks and Prashant Raman and Michael Steinhart, "Consumers embrace connected devices and virtual experiences for the long term," 2023. [Online]. Available: <https://www2.deloitte.com/us/en/insights/industry/telecommunications/connectivity-mobile-trends-survey/2023/connectivity-mobile-trends-survey-full-report.html>

MaDIoT 3.0: Análisis de Ataques a la Demanda y Generación Distribuida en un Sistema Eléctrico

Néstor Rodríguez-Pérez
Instituto de Investigación Tecnológica,
Universidad Pontificia Comillas
nestor.rodriguez@iit.comillas.edu

Javier Matanza
Instituto de Investigación Tecnológica,
Universidad Pontificia Comillas
Madrid, España

Lukas Sigrist
Instituto de Investigación Tecnológica,
Universidad Pontificia Comillas
Madrid, España

Jose Luis Rueda Torres
Delft University of Technology, Países Bajos

Gregorio López López
Instituto de Investigación Tecnológica, Universidad Pontificia Comillas

Resumen—Este artículo analiza el impacto y la eficacia de los ataques MaDIoT 3.0 en el modelo PST-16, un sistema europeo simplificado. Estos ataques, de carácter novedoso, permiten comprometer de forma simultánea dispositivos IoT de alta potencia en la demanda y recursos de generación distribuida, como inversores fotovoltaicos. Los resultados muestran que la incorporación de generación solar fotovoltaica distribuida reduce tanto la tasa de éxito como el impacto de los ataques MaDIoT centrados en la alteración de la demanda, en comparación con un sistema sin dicha generación. En los ataques MaDIoT 3.0, la manipulación de la demanda resulta más determinante para el éxito global del ataque que la generación distribuida. Asimismo, se evidencia que la escalabilidad y la replicabilidad local de dispositivos IoT vulnerables de alta potencia son factores más críticos que su despliegue en áreas geográficas extensas.

Index Terms—MaDIoT, sistemas eléctricos, estabilidad, ciberataque

Tipo de contribución: Investigación ya publicada (límite 2 páginas): "MaDIoT 3.0: Assessment of Attacks to Distributed Energy Resources and Demand in a Power System"[1]

I. INTRODUCCIÓN

El creciente uso de dispositivos de Internet de las Cosas (IoT) y de Recursos Energéticos Distribuidos (DER) está ampliando la superficie de ciberataque de los sistemas eléctricos. Además de los ataques a sistemas de control, la manipulación coordinada de dispositivos IoT de alta potencia puede reducir los márgenes de seguridad de la red eléctrica y provocar la actuación de protecciones.

Los ataques MaDIoT (Manipulation of Demand via IoT) han sido analizados previamente en distintos sistemas eléctricos [2, 3, 4], mostrando que su impacto depende en gran medida de las características del sistema afectado. El artículo publicado que aquí se resume presenta y estudia los ataques MaDIoT 3.0, que combinan la manipulación de demanda y la desconexión de generación fotovoltaica distribuida, con el objetivo de responder a dos preguntas:

- P1: ¿Cómo afecta la presencia de generación solar fotovoltaica distribuida al éxito de los ataques de MaDIoT 1.0?
- P2: ¿Cuál es el éxito y el impacto de los ataques de MaDIoT 3.0 en comparación con los ataques de MaDIoT 1.0 en el mismo sistema eléctrico?

II. METODOLOGÍA

El estudio se realiza sobre el modelo PST-16, una representación simplificada del sistema eléctrico europeo con tres

áreas, utilizando DigSILENT PowerFactory. En el modelo se incluyen protecciones de subfrecuencia, sobrefrecuencia, subtensión y sobretensión, cuya configuración se detalla en [1], así como las características del modelo de red PST-16 empleado. Se consideran escenarios con y sin generación fotovoltaica distribuida en el área C del PST-16, con un nivel de penetración de DER representativo de escenarios realistas para 2030 [1].

Los ataques analizados corresponden a MaDIoT 1.0, donde únicamente se incrementa la demanda a través de dispositivos IoT comprometidos, y MaDIoT 3.0, que combinan el aumento de demanda con la desconexión coordinada de DER. En todos los casos se asume que el atacante no dispone de información detallada del sistema, seleccionándose de forma aleatoria los nodos atacados y evaluándose el éxito del ataque en función de si ha habido alguna protección que ha actuado. Para facilitar la comprensión de los resultados, la Figura 1 detalla el sistema seguido para nombrar los escenarios analizados.




Figura 1. Nomenclatura de los escenarios analizados en [1]

III. RESULTADOS

Para responder a las preguntas de investigación planteadas, se realizaron simulaciones de distintos escenarios en PowerFactory (Tabla IV en el artículo original [1]). Esta sección resume los principales hallazgos en [1]; debido al límite de extensión del resumen, no es posible incluir todas las figuras y tablas.

III-A. Influencia de los DER en los ataques MaDIoT 1.0 (Pregunta 1)

Los resultados de la Figura 2 muestran que la inclusión de generación solar distribuida en el área C del PST-16




Figura 2. Éxito de los ataques MaDIoT 1.0 en el PST-16 con y sin DER

reduce significativamente la tasa de éxito y el impacto de los ataques MaDIoT 1.0 en comparación con el sistema original sin DER. En los escenarios analizados, las tasas de éxito son estadísticamente más bajas cuando hay DER (nivel de significación del 5%). Solo se observan tasas de éxito significativas en los ataques de mayor magnitud (aumento de la demanda de 1500 MW).

Esto se explica porque, aunque la conexión de DER reduce la inercia síncrona, la frecuencia no es el principal factor que provoca inestabilidad de la red en estos escenarios. En cambio, el éxito del ataque está relacionado principalmente con la tensión en la red y el ángulo de rotor de los generadores. La conexión de DER aumenta las tensiones de los buses en el área C en un 1% de media, lo que coloca al sistema en mejores condiciones para enfrentarse al ataque.

Los ataques de mayor impacto que se analizan de manera detallada en [1] muestran que, en el sistema con DER, los ataques principalmente provocan caídas progresivas de tensión en los buses atacados, lo que conduce a una desconexión limitada de cargas por subtensión y a la eventual estabilización del sistema. La desconexión máxima de demanda observada en presencia de DER es de aproximadamente el 1,2% de la demanda inicial, lo que es sustancialmente inferior al 13-20% registrado en ataques equivalentes en el sistema sin DER. Simulaciones adicionales confirman que los escenarios de ataque que tienen éxito en el sistema PST-16 básico se vuelven ineficaces cuando hay DER. En general, la sustitución del 10% de la generación centralizada por generación de DER mejora notablemente la robustez del sistema PST-16 frente a los ataques MaDIoT 1.0.

III-B. Comparativa entre los ataques MaDIoT 1.0 y MaDIoT 3.0 (Pregunta 2)

Los ataques MaDIoT 3.0 presentan tasas de éxito más bajas que los ataques MaDIoT 1.0 con potencia total equivalente. Los resultados indican que la cantidad y la concentración de la demanda comprometida tienen una mayor influencia en el éxito del ataque que la desconexión de los DER por sí sola. Además, los ataques centrados en unos pocos nodos de demanda producen mayores caídas de tensión locales y, por lo tanto, son más disruptivos que los ataques distribuidos entre muchos nodos.

Los análisis de los casos de MaDIoT 3.0 de gran magnitud muestran caídas moderadas de tensión con algunas desconexiones de demanda por este motivo, con una dinámica estable del ángulo del rotor y sin inestabilidad de frecuencia. Cuando se comparan con los ataques MaDIoT 1.0 de magnitud teórica

similar, los ataques MaDIoT 3.0 causan perturbaciones menores en el sistema, lo que indica un papel más relevante de la manipulación de la demanda en las consecuencias del ataque.

Los escenarios en los que la demanda comprometida y los DER atacados se encuentran en zonas diferentes no aumentan significativamente ni la tasa de éxito ni el impacto de los ataques. Aunque atacar la demanda en la zona A produce una tasa de éxito ligeramente superior a la de la zona C, el impacto global en el sistema sigue siendo comparable y reducido. Los ataques dirigidos a la demanda en la zona B no tienen éxito en las condiciones analizadas.

Por último, distribuir la demanda comprometida entre un mayor número de nodos reduce drásticamente la tasa de éxito, lo que confirma que la tensión localizada es un factor clave para la eficacia del ataque en el PST-16. Sin embargo, cuando los ataques a los DER se combinan con ataques a la demanda moderadamente distribuidos, la tasa de éxito y el impacto aumentan considerablemente. En el escenario combinado más grave, se observan colapsos de tensión, desconexiones de generadores y desconexiones de demanda a gran escala, lo que indica la posibilidad de apagones en áreas extensas.

IV. CONCLUSIONES

Los resultados muestran que añadir un 10% de generación solar distribuida (reemplazando generación centralizada) en el área C del sistema PST-16, resultó en un aumento promedio de tensión de un 1%, reduciendo la efectividad de los ataques MaDIoT 1.0 en comparación con escenarios sin DER (Pregunta 1).

En el caso de los ataques MaDIoT 3.0 (Pregunta 2), los resultados indican que la demanda desempeña un papel más decisivo en el éxito del ataque que el DER. Dispersar la demanda atacada en múltiples nodos o enfocar el ataque a la demanda de áreas distintas a las que contienen el DER comprometido redujo significativamente la tasa de éxito de MaDIoT 3.0. En consecuencia, la concentración de dispositivos IoT vulnerables en un número limitado de nodos puede representar un riesgo mayor que una vulnerabilidad generalizada en dispositivos distribuidos en el sistema.

AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por el proyecto eFORT (European Union's Horizon Europe Research and Innovation programme, Grant Agreement No 101075665); y el proyecto RESPONSE (European Union's Horizon 2020 research and innovation programme, Grant Agreement No. 957751).

REFERENCIAS

- [1] N. Rodríguez-Pérez, J. Matanza, L. Sigrist, J. Rueda Torres, and G. López, "Madiot 3.0: Assessment of attacks to distributed energy resources and demand in a power system," *IEEE Open Access Journal of Power and Energy*, vol. 12, pp. 552–563, 2025.
- [2] S. Soltan, P. Mittal, and H. V. Poor, "Blacklot: Iot botnet of high wattage devices can disrupt the power grid," in *27th USENIX Security Symposium*, 2018, pp. 15–32.
- [3] T. Shekari, A. A. Cardenas, and R. Beyah, "Madiot 2.0: Modern high-wattage iot botnet attacks and defenses," in *31st USENIX Security Symposium*, 2022, pp. 3539–3556.
- [4] N. Rodríguez-Pérez, J. Matanza Domingo, L. Sigrist, J. L. Rueda Torres, and G. López López, "Confronting the threat: Analysis of the impact of madiot attacks in two power system models," *Energies*, vol. 16, no. 23, 2023.

Evaluando Riesgos de Ciberseguridad en Infraestructuras Distribuidas. El patrón MARISMA-DS

José L. Ruiz-Catalán, Ángel Suárez-Bárcena, Antonio Santos-Olmo, Luis E. Sánchez,

David G. Rosado, Eduardo Fernández-Medina

GSyA Research Group

Universidad de Castilla-La Mancha, Ciudad Real, España

{joseluis.ruiz, angel.sbarcena, antonio.santosolmo, luise.sanchez, david.grosado, eduardo.fdezmedina}@uclm.es

Resumen—Los sistemas distribuidos habilitan servicios escalables y de alta disponibilidad mediante la cooperación de múltiples nodos; sin embargo, su adopción incrementa la superficie de ataque y la complejidad operativa. La heterogeneidad de activos (servidores, microservicios, contenedores, dispositivos de borde y entornos multi-nube) introduce dependencias dinámicas, configuraciones cambiantes y dominios administrativos diversos, donde una debilidad local puede propagarse y afectar la continuidad del servicio. En este contexto altamente dinámico, las metodologías tradicionales de evaluación de riesgos presentan limitaciones de escalabilidad, ya que no incorporan con agilidad la suma continua de nuevos componentes ni mantienen un análisis coherente frente a arquitecturas crecientes y altamente interdependientes. Este trabajo propone un enfoque basado en MARISMA y eMARISMA para gestionar riesgos en sistemas distribuidos. Definimos un patrón de riesgos alineado con ENISA e ISO 27001 y lo validamos mediante un caso de estudio en una clínica médica real.

Index Terms—Distributed Systems, Risk Management, Cybersecurity, MARISMA, Healthcare Case Study.

Tipo de contribución: *Investigación original*

I. INTRODUCCIÓN

Los sistemas distribuidos modernos basados en arquitecturas cloud-native, despliegues edge-cloud, microservicios y ecosistemas con dispositivos conectados (IoT y embebidos) sustentan organizaciones y servicios críticos [1]. Aunque su adopción se asocia a escalabilidad, elasticidad y tolerancia a fallos [2], reconfigura el riesgo al diluir el perímetro y distribuir la exposición entre capas interdependientes (dispositivos, redes, plano de control, APIs, datos y cadena de suministro), donde los efectos en cascada amplifican incidentes locales [3]. En consecuencia, credenciales comprometidas, dependencias vulnerables o configuraciones erróneas pueden habilitar movimiento lateral y comprometer simultáneamente disponibilidad, confidencialidad e integridad, agravado por multi-tenant y responsabilidad compartida, observabilidad parcial, componentes efímeros, automatización intensiva (CI/CD, IaC) y heterogeneidad de proveedores, donde el “eslabón más débil” condiciona la postura global [4].

Pese a la estandarización de la evaluación de riesgos, su aplicación directa a estos entornos presenta limitaciones por supuestos de estabilidad (inventarios estáticos, fronteras claras y análisis periódicos) y dependencia de juicio experto, dificultando capturar dinamismo y dependencias técnicas/organizativas [5]. En cloud y sistemas desagregados se

señalan, entre otros, retos en la modelización de riesgos interdependientes, la representación de la cadena de suministro y la actualización continua ante cambios frecuentes [6]; de forma convergente, la literatura en IoT [7], CPS [8] y OT [9] refuerza que los enfoques estáticos pierden precisión frente a estados cambiantes y amenazas evolutivas, motivando aproximaciones más dinámicas basadas en taxonomías reutilizables y automatización [10].

Para abordar este vacío proponemos MARISMA-DS, un patrón para mejorar el análisis de riesgos en entornos distribuidos mediante reutilización de conocimiento, trazabilidad entre catálogos y actualización continua. Basado en la familia MARISMA [11], integra recomendaciones de ENISA y estándares internacionales para estructurar dominios, objetivos de control y dimensiones de impacto, incorporando panoramas de amenazas en escenarios donde la distribución es determinante.

En línea con el documento de referencia, se apoya en MARISMA-CPS [12] y MARISMA-IoT [13], pero desplaza el foco del riesgo hacia el plano de control, servicios, datos y dependencias externas (supply chain y cloud) [14]. Para ello, organiza el conocimiento en catálogos y matrices que relacionan activos, amenazas y dimensiones, explicitando qué controles mitigan qué familias de amenazas y reduciendo la subjetividad en la priorización.

El resto del artículo se organiza como sigue: en la sección II se encuentra la revisión del estado del arte; la sección III contiene la presentación del marco MARISMA; en la sección IV nos encontramos la descripción de MARISMA-DS; en la sección V se realiza la validación mediante un caso de estudio real; y por último, en la sección VI se exponen las conclusiones y trabajo futuro.

II. TRABAJO RELACIONADO

La adopción de arquitecturas distribuidas (cloud-native, edge-cloud, microservicios, IoT/embebidos, 5G y ecosistemas multi-proveedor) ha incrementado la heterogeneidad técnica y regulatoria de los sistemas actuales. Aunque existen guías y estándares específicos por dominio, suelen ofrecer una cobertura parcial o sectorial, lo que dificulta su aplicación integrada cuando múltiples dominios coexisten en una misma infraestructura

En gestión de seguridad, ISO/IEC 27001:2022 [15] e ISO/IEC 27005:2022 [16] proporcionan un marco consolidado

para SGSI y evaluación de riesgos, pero con un enfoque generalista que no captura en detalle particularidades de entornos distribuidos (interdependencias dinámicas, orquestación automatizada o exposición por cadena de suministro). De forma complementaria, ISO/IEC 30141:2024 [17] aporta una arquitectura de referencia IoT e introduce dimensiones clave (p. ej., disponibilidad, confidencialidad, integridad, resiliencia y cumplimiento), sin incorporar un mecanismo integrado para relacionar sistemáticamente activos, amenazas y controles en ecosistemas heterogéneos.

El NIST dispone de marcos relevantes para dominios concretos, como NIST IR 8259A [18] (IoT), NIST SP 800-82 [19] (ICS/OT) y NIST SP 800-161 [20] (cadena de suministro). Asimismo, ENISA ha publicado panoramas de amenazas y buenas prácticas para múltiples sectores, incluyendo supply chain [21], 5G [22], sanidad [23], ferrocarril [24], IoT (supply chain, CII, smart manufacturing y ciclo de desarrollo) [25], [26], [27], [28], automoción [29], marítimo [30], espacio [31], smart home [32], [33] y M2M [34]. No obstante, su aplicación aislada tiende a fragmentar el análisis cuando se requiere una evaluación transversal que abarque simultáneamente cloud, edge, embebidos y proveedores externos.

Aunque metodologías como MAGERIT, OCTAVE o CO-RAS se han adaptado a contextos emergentes, dichas extensiones suelen mantener estructuras rígidas o evaluaciones predominantemente estáticas, limitando su reutilización en sistemas dinámicos e interdependientes. En particular, la falta de un patrón unificado que integre catálogos de activos, amenazas, dimensiones y controles procedentes de múltiples marcos restringe la trazabilidad y la escalabilidad del análisis.

En este marco se sitúa MARISMA-DS como patrón para el análisis de riesgos en entornos distribuidos, cuyo objetivo no es sustituir estándares, sino integrarlos sistemáticamente en un esquema unificado que mejore la identificación, evaluación y priorización del riesgo. MARISMA-DS consolida las recomendaciones de ENISA citadas junto con ISO/IEC 27001:2022 [15], ISO/IEC 27005:2022 [16] e ISO/IEC 30141:2024 [17], organizándolas en cuatro catálogos taxonómicos (dominios y objetivos de control, activos, amenazas y dimensiones) y matrices de dependencia que explicitan sus relaciones. Con ello, el patrón reduce la fragmentación sectorial y refuerza el análisis de riesgos en infraestructuras donde coexisten servicios cloud, IoT, componentes OT, redes 5G y cadenas de suministro complejas.

III. MARISMA FRAMEWORK

MARISMA [11] es un marco orientado a la gestión dinámica de riesgos de ciberseguridad que prioriza la adaptabilidad al contexto, la reutilización de conocimiento y la reducción de la subjetividad en la valoración del riesgo. Su propuesta metodológica combina un metapatrón reutilizable que define la estructura conceptual de la gestión del riesgo (controles, activos y amenazas) con un conjunto de patrones específicos de dominio que especializan dicho metapatrón para distintos sectores y escenarios operativos.

Tal y como se sintetiza en la Figura 1, MARISMA [11] articula el modelado del riesgo mediante la interacción entre la metamodelación del conocimiento (metapatrón), la instanciación contextual (patrones sectoriales) y un proceso de análisis y gestión que permite desarrollar, aplicar y mantener




Figura 1. MARISMA Framework.

los patrones conforme evolucionan los activos, las amenazas y el entorno operativo. Este enfoque se complementa con un mecanismo de aprendizaje continuo, facilitando la actualización sistemática del conocimiento de riesgos ante nuevos escenarios y evidencias.

Para optimizar su adopción, MARISMA [11] dispone de eMARISMA, una herramienta en la nube que automatiza tareas del análisis y la gestión del riesgo, proporcionando accesibilidad, reducción de costes y tiempos de despliegue, además de escalabilidad para organizaciones de distinto tamaño. Asimismo, eMARISMA habilita la generación de alertas basadas en eventos de seguridad, contribuyendo a una gestión más proactiva y alineada con la operación del sistema.

IV. DEFINICIÓN DEL PATRÓN MARISMA-DS

La definición de MARISMA-DS sistematiza la gestión del riesgo en infraestructuras distribuidas heterogéneas, altamente interdependientes y dinámicas (p. ej., autoescalado, despliegues continuos y cambios de configuración). Para garantizar consistencia, trazabilidad y reutilización, el patrón se fundamenta en estándares y guías. El patrón MARISMA-DS alinea sus dimensiones con ISO/IEC 30141:2024 [17], organiza activos y amenazas a partir de Threat Landscapes y guías de ENISA, y define y traza controles conforme a ISO/IEC 27001:2022 [15].

El patrón se estructura en catálogos (Figura 2) y relaciones explícitas entre dominios, objetivos de control, controles, activos, amenazas y dimensiones, de las que se derivan matrices de correlación para priorizar medidas y monitorizar el riesgo durante el ciclo de vida.

IV-A. Dimensiones

MARISMA-DS define las dimensiones de evaluación del impacto conforme a ISO/IEC 30141:2024 [17], de modo que la estimación del daño refleje propiedades arquitectónicas y operacionales relevantes en infraestructuras distribuidas. Estas dimensiones se emplean para caracterizar el impacto de cada amenaza sobre activos específicos, facilitando una valoración homogénea y mantenible del riesgo en entornos altamente dinámicos y heterogéneos, pudiéndose observar en la Figura 2.

IV-B. Dominios y Objetivos

Los dominios del patrón MARISMA-DS se definen como agrupaciones coherentes de capacidades de seguridad, y se descomponen en objetivos verificables que guían la selección de controles y evidencias. Para asegurar alineación con un marco internacionalmente aceptado, MARISMA-DS adopta




Figura 2. Segmento de los elementos del patrón MARISMA-DS.

como referencia la estructura de ISO/IEC 27001:2022 [15], empleándola como base para organizar objetivos de control (véase la Figura 2) relacionados con, entre otros, gobierno de la seguridad, gestión de activos, control de accesos, criptografía, seguridad de operaciones, comunicaciones, adquisición/ desarrollo/mantenimiento, relaciones con proveedores, gestión de incidentes y continuidad. Esta aproximación aporta trazabilidad directa entre objetivos, controles y riesgos, favoreciendo auditorabilidad y comparabilidad.

IV-C. Activos

El catálogo de activos de MARISMA-DS se elabora a partir de guías y Threat Landscapes de ENISA previamente mencionadas, seleccionando fuentes que cubren escenarios distribuidos, interconectados y sectoriales, y permitiendo modelar la heterogeneidad propia de estos entornos (plataformas, redes, servicios, componentes edge, supply chain, etc.). A partir de estas referencias, el catálogo integra activos físicos, virtuales, lógicos e incluso organizacionales típicos de infraestructuras distribuidas (nodos de cómputo, redes, plataformas de ejecución, servicios, datos y herramientas operacionales), permitiendo además capturar activos transversales como se puede observar en la Figura 2.

IV-D. Amenazas

La identificación y clasificación de amenazas se fundamenta igualmente en ENISA, garantizando un repertorio actualizado y contextualizable de vectores de ataque relevantes para ecosistemas distribuidos que se puede consultar en la Figura 2. El conjunto resultante permite cubrir amenazas especialmente relevantes en infraestructuras distribuidas, como compromiso de la cadena de suministro, errores de configuración a escala, exposición y abuso de interfaces, compromiso de identidades y secretos, movimiento lateral, ataques de denegación de servicio y agotamiento de recursos, y exfiltración o corrupción de datos, entre otras. El catálogo se define de forma que cada amenaza pueda vincularse explícitamente a activos concretos y a las dimensiones afectadas, habilitando análisis consistentes y comparables.

IV-E. Estructuras de correlación del patrón

Finalmente, MARISMA-DS operacionaliza el patrón mediante matrices de correlación que preservan la trazabilidad entre elementos.

IV-E1. Matriz Dominios-Objetivos-Amenazas en infraestructuras distribuidas: La gestión de riesgos en infraestructuras distribuidas requiere una estructura explícita que relacione dominios de seguridad, objetivos de control y amenazas para preservar la trazabilidad del análisis en arquitecturas dinámicas. Con este fin, MARISMA-DS define una matriz de correlación Dominios-Objetivos-Amenazas que representa cómo los dominios, objetivos y controles contribuyen a la cobertura de amenazas, facilitando la detección de brechas y la priorización de medidas. Este enfoque sigue el principio metodológico de patrones previos, orientado a modelar de forma sistemática la contribución de los objetivos de seguridad a la mitigación del riesgo. Cada celda de la matriz indica una relación de mitigación/cobertura, lo que permite identificar objetivos con contribución transversal, objetivos sin cobertura frente a amenazas relevantes y dominios críticos donde la exposición se amplifica por dependencias propias de sistemas distribuidos.

Dado el tamaño de la matriz completa, se presenta una versión reducida con ejemplos representativos (Tabla I). Por ejemplo, en el dominio *Infraestructura*, el objetivo asociado a los controles de *Perímetro de seguridad física* contribuye a mitigar amenazas de *Daño/Pérdida de TI* y *Ataques físicos*, al reducir la probabilidad e impacto de robo, manipulación o destrucción de equipos e instalaciones mediante medidas de control de acceso físico.

IV-E2. Matriz Activos-Amenazas-Dimensiones en infraestructuras distribuidas: De la misma manera que el punto anterior, las infraestructuras distribuidas exige un análisis estructurado que conecte activos, amenazas y dimensiones de seguridad para mantener la trazabilidad del impacto en arquitecturas heterogéneas y dinámicas. Con este fin, MARISMA-DS define una matriz Activos-Amenazas-Dimensiones que relaciona familias/tipos de activos de sistemas distribuidos,

Tabla I
EJEMPLOS REPRESENTATIVOS DE LA MATRIZ DOMINIOS, OBJETIVOS Y FAMILIAS DE AMENAZAS.

Dominio	Objetivo	Familias de Amenazas								
		Actividad Maliciosa	Escuchas / Interceptación	Cortes	Daño / Pérdida IT	Fallos / Mal funcionamiento	Desastre	Ataques físicos	Legal	Propiedad Intelectual
Organizacional	5.1 Políticas para la seguridad de la información	X			X	X			X	X
	5.7 Inteligencia de amenazas	X	X		X	X				
	5.24 Planificación y preparación de la gestión de incidentes	X		X	X	X	X			
Personas	6.1 Comprobación	X			X	X			X	X
	6.3 Concienciación, educación y formación	X			X	X			X	X
	6.8 Notificación de eventos de seguridad	X		X		X				
Infraestructura	7.1 Perímetro de seguridad física				X			X		
	7.5 Protección contra amenazas físicas y ambientales			X	X		X			
	7.8 Emplazamiento y protección de equipos				X			X		
Tecnología	8.5 Autenticación segura	X	X							
	8.9 Gestión de la configuración	X			X	X				
	8.20 Seguridad de redes	X	X	X						

Tabla II
SEGMENTO DE LA MATRIZ DE FAMILIAS Y TIPOS DE AMENAZAS, FAMILIAS DE ACTIVOS, Y DIMENSIONES

Familias de Amenazas	Tipos de Amenazas	Familias de Activos								
		Management & Orchestration	Plataforma & Backend	Comunicaciones	Infraestructura	Aplicaciones & Servicios	Información	Management/ Operation	Supplier/ Supply Chain	... (más familias)
Actividad maliciosa	Malware		A, C, I, RL, RS, CO				C, I, CO			...
	Kits de explotación		A, C, I, RL, RS, CO	A, C, I, RL, RS		A, C, I, RL, RS				...
	Ataques dirigidos		A, C, I, RL, RS, CO	A, C, I, RL, RS	A, I, RL, RS	A, C, I, RL, RS	C, I, CO		C, I, RL, CO	...
... (más familias y tipos de amenazas)										
Escuchas / Interceptación	Man in the middle			A, C, I, RL, RS			C, I, CO		C, I, CO	...
	Secuestro de protocolos de comunicación		A, C, I, RL, RS	A, C, I, RL, RS		A, C, I, RL, RS			C, I, CO	...
	Interceptación de información			C, I, CO			C, I, CO		C, I, CO	...
... (más familias y tipos de amenazas)										
Cortes	Corte de red	A, RL, RS	A, RL, RS	A, RL, RS	A, RL, RS	A, RL, RS	A, RL, RS	A, RL, RS	A, RL, RS	...
	Corte de alimentación	A, RL, RS, S			A, RL, RS, S					...
	Pérdida de servicios de soporte	A, RL, RS, CO	A, RL, RS, CO	A, RL, RS	A, RL, RS	A, RL, RS	A, RL, RS, CO	A, RL, RS, CO	A, RL, RS, CO	...

Dimensiones A:Availability; C:Confidentiality; I:Integrity; RL:Reliability; RS:Resilience; S:Safety; CO:Compliance

familias/tipos de amenazas consolidadas a partir de Threat Landscapes y guías sectoriales de ENISA, y dimensiones alineadas con ISO/IEC 30141:2024 [17].

La matriz explicita qué amenazas afectan a qué activos y qué dimensiones se ven comprometidas, soportando una evaluación de impacto más consistente en presencia de dependencias y propagación. Además, permite priorizar riesgos al identificar combinaciones activo-amenaza con impacto multidimensional, localizar activos transversales cuya afectación amplifica daños en cascada y facilitar la evolución del patrón ante cambios frecuentes, dado que las relaciones se mantienen sobre catálogos y no sobre inventarios estáticos. Por su extensión, se incluye una versión reducida con ejemplos representativos en la Tabla II. En dicha tabla puede observarse que *Escuchas/Interceptación* (p. ej., *Man in the middle*) impacta en activos de *Comunicaciones* sobre *Availability*, *Confidentiality*, *Integrity*, *Reliability* y *Resilience*, y en activos de *Información* y *Supplier/Supply Chain* sobre *Confidentiality*, *Integrity* y *Compliance*, al poder situarse en

tráfico horizontal (entre microservicios) o vertical (cliente-API gateway), alterando comunicaciones y habilitando exfiltración o manipulación. Típicamente, ello se traduce en degradación de servicio y saturación (A), exposición de datos en tránsito (C), modificación de mensajes (I), inestabilidad operativa (RL), mayor esfuerzo/tiempo de contención y recuperación (RS) y potencial incumplimiento regulatorio cuando se afectan datos sensibles (CO).

V. CASO DE ESTUDIO: CLÍNICA REAL

Con el fin de validar la aplicabilidad y escalabilidad del patrón MARISMA-DS en un entorno operativo crítico, se selecciona como caso de estudio una clínica médica privada digitalizada y con un entorno completamente interconectado. Lejos de una infraestructura centralizada, la clínica opera como un ecosistema distribuido, donde múltiples sistemas y dispositivos cooperan de forma continua para sostener la actividad asistencial y administrativa.

Su infraestructura trasciende el HIS/EMR central e integra dispositivos médicos conectados, monitorización, diagnóstico,

estaciones clínicas, servidores locales, servicios cloud, redes segmentadas, telemedicina e IoT para gestión ambiental e instalaciones. Este conjunto intercambia datos en tiempo real —historias clínicas, imágenes, resultados de laboratorio, señales biomédicas y datos administrativos— configurando un entorno altamente interdependiente.

Además, los requisitos regulatorios y la continuidad del cuidado obligan a garantizar que los datos sean íntegros, veraces, disponibles, protegidos y trazables, equilibrando el acceso inmediato ante urgencias con la privacidad y el control estricto de accesos.

Esta arquitectura distribuida amplía la superficie de exposición y crea dependencias críticas entre activos: una indisponibilidad de red puede degradar simultáneamente acceso a EHR, visualización diagnóstica y comunicaciones externas; una vulnerabilidad en un dispositivo conectado puede comprometer la integridad clínica o incluso la seguridad del paciente. La heterogeneidad tecnológica, la coexistencia de proveedores y las exigencias de protección de datos, trazabilidad y continuidad incrementan la complejidad de la gestión del riesgo.

El caso de estudio modela la clínica como un sistema socio-técnico distribuido, identificando familias de activos, amenazas y dimensiones de impacto conforme a MARISMA-DS, con el objetivo de evidenciar cómo el patrón estructura el análisis de riesgos, prioriza controles y refuerza la resiliencia operativa y asistencial.

V-A. Definiendo las dimensiones para el caso de estudio

Para evaluar los riesgos en una clínica real, se han considerado todas las dimensiones de ciberseguridad definidas en el patrón ya que son fundamentales para evaluar el impacto de las distintas amenazas en los diferentes activos que componen el caso de estudio, los cuales se pueden ver en la Figura 2. Estas dimensiones permiten analizar la seguridad desde diferentes perspectivas.

V-B. Definiendo los activos para el caso de estudio

Siguiendo el enfoque de instanciación del patrón, los activos del caso de estudio se identifican, clasifican e instancian a partir de las familias y tipos definidos en MARISMA-DS, obteniendo un inventario estructurado de activos representativos de la clínica (véase la Tabla III o el enlace a pie de página¹ para ver el catálogo completo). Esta clasificación organiza los activos por familias, facilitando la trazabilidad posterior con amenazas y dimensiones.

Una vez identificados, los activos se incorporan en eMARISMA, donde se gestionan de forma jerárquica (familia-tipo-activo) y se complementan con información relevante, como el valor del activo, que se utiliza para priorizar y mejorar la precisión del análisis del riesgo. Tras su carga, la herramienta permite explotar las relaciones del patrón entre activos, amenazas y dimensiones (establecidas en la Tabla II), proporcionando una visión operativa del riesgo y soportando la toma de decisiones en un entorno sanitario real.

V-C. Definiendo las amenazas para el caso de estudio

Una vez identificados e instanciados los activos de la clínica, el siguiente paso consiste en definir las amenazas

relevantes que pueden materializarse en el entorno distribuido analizado. Dado que la clínica opera como un ecosistema interconectado, la superficie de exposición se amplía significativamente, haciendo necesario un enfoque sistemático y estructurado.

Siguiendo el patrón MARISMA-DS, las amenazas del caso de estudio se seleccionan e instancian en las familias y tipos de amenazas definidos en el propio patrón, como se puede observar en la Tabla IV. En el contexto específico de la clínica, las amenazas adquieren particular criticidad. Por ejemplo, la introducción de malware en un servidor que aloja el sistema de historia clínica electrónica puede comprometer simultáneamente la disponibilidad, integridad y confidencialidad de los datos clínicos; una interceptación en las comunicaciones entre dispositivos médicos y el backend puede afectar la exactitud de resultados diagnósticos; y un corte de red puede paralizar consultas, pruebas diagnósticas y procesos administrativos. Asimismo, la dependencia de proveedores externos (mantenimiento de equipos médicos, servicios cloud, conectividad) introduce riesgos adicionales asociados a la cadena de suministro.

Las amenazas instanciadas se incorporan en eMARISMA y se relacionan con las familias de activos previamente definidas, permitiendo su posterior correlación con las dimensiones de impacto (Availability, Confidentiality, Integrity, Reliability, Resilience, Safety y Compliance). Este proceso garantiza que el análisis del riesgo no se limite a una enumeración genérica de amenazas, sino que esté contextualizado en la arquitectura distribuida real de la clínica, facilitando la priorización de medidas de mitigación y la mejora de la resiliencia asistencial.

V-D. Análisis de riesgos para el caso de estudio

El siguiente paso en el análisis de riesgos es evaluar el impacto de las amenazas en los activos, considerando sus dimensiones. Esto permite calcular el daño total sufrido cuando una amenaza afecta el sistema, basado en el daño por dimensión. La herramienta visualiza la relación entre amenazas, activos y dimensiones de la Tabla II con los valores asignados previamente en la Figura 3.

Los valores predeterminados de degradación por dimensiones se establecen según el porcentaje definido en el paso anterior en la Figura 3 y por la relación entre activos, amenazas y dimensiones definidas en el patrón (ver Tabla II). Estos valores pueden asignarse automáticamente según el conocimiento de la herramienta o ser ajustados por expertos en seguridad, quienes pueden modificarlos según su criterio.

Durante la ejecución del caso de estudio, se registró un incidente de acceso no autorizado, por parte de un trabajador, a información clínica fuera de su ámbito funcional, evidenciado mediante trazas de auditoría y correlación de eventos de acceso. Este evento motivó la recalibración inmediata de los parámetros de la amenaza asociada (acceso indebido/abuso de privilegios) sobre los activos de la familia *Información*, actualizando los valores de ocurrencia y de degradación por dimensiones (en particular, Privacidad/Legal) conforme a la criticidad del entorno sanitario. A partir de dicha actualización, la herramienta recalculó el riesgo (inherente y residual) y reordenó la criticidad de los activos afectados, habilitando la priorización y aplicación dirigida de controles (p. ej., refuerzo del least privilege mediante RBAC/ABAC, revisión

¹https://github.com/GSYAtools/CE_Marisma-DS_Clinica/blob/main/MARISMA_DS_Caso_de_Estudio.pdf

Tabla III
SEGMENTO DE ACTIVOS CRÍTICOS DEL CASO DE ESTUDIO DEFINIDOS EN EL PATRÓN MARISMA-DS.

Patrón MARISMA-DS		Patrón instanciado	
Familias de Activos	Tipos de Activos	Elemento	Modelo
Dispositivos del ecosistema	Sistemas embebidos	Máquina de rayos X	Toshiba Rotanode E7239X
	Sistemas embebidos	Sistemas de ultrasonido	Esaote A70
	Sistemas embebidos	Sistemas de mamografía	Metaltronica FLAT SE Digital
	Equipamiento de usuario	Teléfonos móviles corporativos	Samsung
Información	En reposo	Base de datos sanitaria en la nube	Datos reales / falsos
Infraestructura	Servidores	Servidores locales	ASUS Xeon
	Sistemas de detección	Cámaras CCTV cableadas	Sony
	Activos de seguridad	Cortafuegos	Real
Personas/seres vivos	Operadores/Trabajadores	Miembros del personal	Datos reales / falsos
Parte de los dispositivos	Sensores	Sensores médicos	Varios proveedores
...	...	...	...




Figura 3. Ocurrencia y Degradación de los activos por amenaza / Degradación x Dimensiones x Activos x Amenazas

Tabla IV
SEGMENTO DE AMENAZAS CRÍTICAS DEL CASO DE ESTUDIO.

Familia Amenazas	Tipo Amenazas	Amenaza Caso Estudio
Actividad maliciosa	Kits de explotación	Explotación vulnerabilidades conocidas en equipos sanitarios de larga vida útil y difícil actualización.
Actividad maliciosa	Modificación de información	Alteración intencionada de datos sanitarios.
Interceptación	Interceptación de datos	Intercepción de datos en tránsito (incluyendo terceros/proveedores).
Fallos / Malfuncionamiento	Fallo de dispositivos	Indisponibilidad o degradación de equipos/servicios críticos.
Fallos / Malfuncionamiento	Filtración de información sensible	Exposición o fuga de información clínica por descuidos o gestión inadecuada de documentos/datos.
...	...	...

y segregación de funciones, endurecimiento de procesos de provisión/anulación de permisos, etc.) Tras su implantación, se recalculó el riesgo residual, verificándose una reducción del nivel de criticidad asociado a la amenaza y una mejora en la contención de impactos sobre los activos dependientes.




Figura 4. Niveles de cobertura de los controles del caso de estudio.

V-E. Resultados del análisis de riesgos

Para concluir el análisis de riesgos en la clínica, se realiza una verificación interna apoyada en una lista de verificación de seguridad, cuyo objetivo es evaluar la cobertura de los controles y su grado de implantación, proporcionando una visión consolidada del estado de la seguridad y facilitando la priorización de acciones correctivas como se puede observar en la Figura 4. En este entorno clínico distribuido, esta verificación ha permitido identificar debilidades transversales que pueden amplificar el impacto en cascada (p. ej., fallos de conectividad, identidad, o servicios compartidos), áreas con cobertura insuficiente y su potencial relación con los



Figura 5. Mapa de calor con riesgos inherentes y residuales.




Figura 6. Riesgo calculado por tipo de activo.

riesgos dominantes del caso de estudio. Todo esto es apoyado con diversas evaluaciones mediante diagramas tipo Kiviat (a nivel global, por dominio y por objetivo), así como mapas de calor que comparan riesgo inherente y riesgo residual tras la aplicación de controles (Véase la Figura 5), proporcionando una vista agregada y accionable para la dirección de la clínica y el responsable de seguridad. En paralelo, el sistema presenta información detallada del riesgo por familia/tipo de activo y por nivel de amenaza como se puede observar en la Figura 6, calculando valores promedio que permiten detectar qué componentes concentran mayor exposición y requieren medidas prioritarias.

Finalmente, la aplicación del patrón MARISMA-DS ha reducido el tiempo requerido para la realización del análisis de riesgos en un 55 % respecto a otros métodos tradicionales, manteniendo la trazabilidad y consistencia metodológica, ya que el proceso pasó de 12 meses con métodos tradicionales a 5,4 meses con MARISMA-DS. Asimismo, gracias a las taxonomías del patrón, se han identificado activos y amenazas previamente no contemplados por la clínica, incrementando el inventario en un 27 % para activos y en un 62 % para amenazas, lo que evidencia una mejora sustancial en la exhaustividad del análisis. El patrón también ha permitido identificar aquellos activos que concentran la mayor densidad de amenazas (véase la Figura 6) y de los cuales dependen otros activos, elevando su criticidad y habilitando, en consecuencia, la priorización de controles orientados a dichos activos y a las amenazas que los afectan. Debido a lo anterior, y a la utilización sistemática de las taxonomías junto con el cálculo derivado de las matrices de relaciones, la aplicación del patrón ha permitido estimar de forma objetiva el nivel de riesgo de la clínica. En particular, la ejecución de los cálculos sobre una base metodológica estandarizada reduce la dependencia de juicios ad-hoc, eliminando márgenes de subjetividad y evitando espacio para la especulación o interpretaciones no trazables en el proceso de análisis.

V-F. Lecciones aprendidas

Gracias al caso de estudio se han identificado áreas de mejora del patrón MARISMA-DS, particularmente en la taxonomía de activos, donde se han incorporado nuevos tipos para aumentar su cobertura operativa (p. ej., dentro de Infraestructura, el tipo de activo Infraestructura de Virtualización). Asimismo, se han detectado relaciones activo-amenaza no cubiertas previamente en las matrices de relaciones, junto

con las dimensiones de impacto afectadas que requerían ser explicitadas porque existía una carencia de sistematización formal por realizarse todas las operaciones de seguridad ad-hoc y no mediante un patrón. Por ejemplo, en la matriz activo-amenaza se añadió para la amenaza *Intercepción de datos* la dimensión *Legal* sobre los activos asociados a *Información*. De manera complementaria, debido a la criticidad de dicha amenaza en el entorno clínico analizado, el porcentaje de impacto de la dimensión *Legal* para *Intercepción de datos* se recalibró al alza, pasando del 60 % al 80 %, reflejando con mayor fidelidad las implicaciones regulatorias y de cumplimiento. En conjunto, estas observaciones han permitido refinar y fortalecer el patrón, incrementando su completitud, precisión y aplicabilidad en entornos distribuidos.

VI. CONCLUSIONES

Este trabajo ha presentado MARISMA-DS, un patrón del marco MARISMA orientado al análisis y gestión de riesgos en infraestructuras distribuidas caracterizadas por heterogeneidad de activos, elevada interdependencia, fuerte dependencia de las restricciones de los fabricantes tecnológicos y evolución continua, integrando y relacionando dominios y objetivos de control, familias de activos, familias y tipos de amenazas y dimensiones de impacto, facilitando la trazabilidad del riesgo y su actualización ante cambios frecuentes en la arquitectura.

La validación en una clínica privada real confirma su aplicabilidad en entornos críticos distribuidos, al mejorar la priorización de activos y amenazas críticas mediante la explicitación de relaciones amenaza-activo-dimensión, reducir el esfuerzo del análisis mediante catálogos y matrices reutilizables, y homogeneizar la categorización del inventario, reforzando la resiliencia operativa y la capacidad de toma de decisiones del responsable de seguridad que desemboca en una seguridad real implementada y medible. Asimismo, el caso de estudio ha permitido refinar el patrón, extendiendo la taxonomía de activos e incorporando relaciones y dimensiones previamente no cubiertas, incrementando su completitud y precisión.

Como trabajo futuro, se prevé ampliar la base de referencia incorporando estándares específicos orientados a Industria 4.0, entornos sanitarios, etc. con el fin de alinear objetivos y controles con requisitos propios de estos entornos. Adicionalmente, se desarrollarán nuevos casos de estudio en sectores sustancialmente diferentes para evaluar su generalización, fortalecer la cobertura del patrón y sostener un proceso de validación continua y mejora incremental.

AGRADECIMIENTOS

Esta publicación no hubiera sido posible sin el apoyo de los siguientes proyectos: Di4SPDS (PCI2023145980-2), financiado por MCIN/AEI/10.13039/501100011033 y por la Unión Europea (Programa Chist-Era); KOSMOS-UCLM (PID2024-155363OB-C44) financiado por MCIN/AEI/10.13039/501100011033/FEDER, UE; AURORA (SBPLY/24/180225/000074), financiado por la Consejería de Educación, Cultura y Deportes de la JCCM, y FEDER (Programa Operativo de CLM 2021–2027); RADAR (2025-GRIN-38447) financiado por FEDER; y la Ayuda RED2024-154240-T financiada por MICIU/AEI/10.13039/501100011033.

REFERENCIAS

- [1] C. Pahl, A. Brogi, J. Soldani, and P. Jamshidi, "Cloud container technologies: A state-of-the-art review," *IEEE Transactions on Cloud Computing*, vol. PP, pp. 1–1, 05 2017.
- [2] R. T. Maderazo and J. I. Teleron, "Decentralized architectures: A paradigm for scalable, fault-tolerant, and efficient distributed systems," *Engineering and Technology Journal*, 2024.
- [3] A. Alwarafy, K. A. Al-Thelaya, M. Abdallah, J. Schneider, and M. Hamdi, "A survey on security and privacy issues in edge-computing-assisted internet of things," *IEEE Internet of Things Journal*, vol. 8, no. 6, pp. 4004–4022, 2021.
- [4] A. War, A. Diallo, A. Habib, J. Klein, and T. F. Bissyandé, "Vulnerabilities in infrastructure as code: what, how many, and who?" *Empirical Software Engineering*, vol. 30, no. 5, p. 120, 2025.
- [5] O. Akinrolabu, J. R. Nurse, A. Martin, and S. New, "Cyber risk assessment in cloud provider environments: Current models and future needs," *Computers & Security*, vol. 87, p. 101600, 2019.
- [6] S. Drissi, M. Chergui, and Z. Khatar, "A systematic literature review on risk assessment in cloud computing: Recent research advancements," *IEEE Access*, vol. 13, pp. 76 289–76 307, 2025.
- [7] J. R. C. Nurse, S. Creese, and D. De Roure, "Security risk assessment in iot systems," *IT Professional*, vol. 19, no. 5, pp. 20–26, 2017.
- [8] A. Tantawy, S. Abdelwahed, A. Erradi, and K. Shaban, "Model-based risk assessment for cyber physical systems security," *Computers & Security*, vol. 96, p. 101864, 2020.
- [9] N. Halawi Ghoson, V. Meyrueis, K. Benfriha, T. Guiltat, and S. Loubère, "A review on the static and dynamic risk assessment methods for ot cybersecurity in industry 4.0," *Computers & Security*, vol. 150, p. 104295, 2025.
- [10] M. Waqdan, H. Louafi, and M. Mouhoub, "Security risk assessment in iot environments: A taxonomy and survey," *Computers & Security*, vol. 154, p. 104456, 2025.
- [11] L. E. Sánchez, A. Santos-Olmo, D. G. Rosado, C. Blanco, M. A. Serrano, H. Mouratidis, and E. Fernández-Medina, "Marisma: A modern and context-aware framework for assessing and managing information cybersecurity risks," *Computer Standards & Interfaces*, vol. 92, p. 103935, 2025.
- [12] D. G. Rosado, A. Santos-Olmo, L. E. Sánchez, M. A. Serrano, C. Blanco, H. Mouratidis, and E. Fernández-Medina, "Managing cybersecurity risks of cyber-physical systems: The marisma-cps pattern," *Computers in Industry*, vol. 142, p. 103715, 2022.
- [13] J. L. Ruiz Catalán, A. Santos-Olmo Parra, D. García Rosado, L. E. Sánchez Crespo, and E. Fernández-Medina Patón, "Cybersecurity risk analysis and management in IoT environments: The MARISMA-IoT pattern," *Research Square*, Sep. 2025.
- [14] "Security strategies for microservices-based application systems," National Institute of Standards and Technology (NIST), Tech. Rep. NIST Special Publication 800-204, 2019.
- [15] "ISO/IEC 27001:2022 Information security, cybersecurity and privacy protection — Information security management systems — Requirements," International Organization for Standardization, Geneva, Switzerland, International Standard, 2022. [Online]. Available: <https://www.iso.org/standard/27001>
- [16] "ISO/IEC 27005:2022 Information security, cybersecurity and privacy protection — Guidance on managing information security risks," International Organization for Standardization, Geneva, Switzerland, International Standard, 2022. [Online]. Available: <https://www.iso.org/standard/80585.html>
- [17] "ISO/IEC 30141:2024 Internet of Things (IoT) — Reference Architecture," International Organization for Standardization, Geneva, Switzerland, International Standard, 2024. [Online]. Available: <https://www.iso.org/standard/65695.html>
- [18] K. A. Megas, M. Fagan, K. Scarfone, and M. Smith, "IoT Device Cybersecurity Capability Core Baseline," National Institute of Standards and Technology (NIST), Tech. Rep. NIST Interagency or Internal Report (IR) 8259A, 2020.
- [19] K. Stouffer, V. Pillitteri, S. Lightman, M. Abrams, and A. Hahn, "Guide to Industrial Control Systems (ICS) Security," National Institute of Standards and Technology (NIST), Tech. Rep. NIST Special Publication 800-82 Revision 2, 2015.
- [20] J. Boyens, C. Paulsen, R. Moorthy, and N. Bartol, "Cybersecurity Supply Chain Risk Management Practices for Systems and Organizations," National Institute of Standards and Technology (NIST), Tech. Rep. NIST Special Publication 800-161 Revision 1, 2022.
- [21] "Threat Landscape for Supply Chain Attacks," European Union Agency for Cybersecurity (ENISA), Heraklion, Greece, Technical Report, 2021. [Online]. Available: <https://www.enisa.europa.eu/publications/threat-landscape-for-supply-chain-attacks>
- [22] "ENISA 5G Threat Landscape — Update," European Union Agency for Cybersecurity (ENISA), Heraklion, Greece, Technical Report, 2022. [Online]. Available: <https://www.enisa.europa.eu/publications/enisa-5g-threat-landscape-update>
- [23] "Procurement Guidelines for Cybersecurity in Hospitals," European Union Agency for Cybersecurity (ENISA), Heraklion, Greece, Technical Report, 2020. [Online]. Available: <https://www.enisa.europa.eu/publications/procurement-guidelines-for-cybersecurity-in-hospitals>
- [24] "Railway Cybersecurity: Good Practices in Cyber Risk Management," European Union Agency for Cybersecurity (ENISA), Heraklion, Greece, Technical Report, 2021. [Online]. Available: <https://www.enisa.europa.eu/publications/railway-cybersecurity>
- [25] "Guidelines for Securing the Internet of Things (IoT) — Supply Chain," European Union Agency for Cybersecurity (ENISA), Heraklion, Greece, Technical Report, 2020. [Online]. Available: <https://www.enisa.europa.eu/publications/guidelines-for-securing-the-internet-of-things>
- [26] "Baseline Security Recommendations for IoT in the Context of Critical Information Infrastructures," European Union Agency for Network and Information Security (ENISA), Heraklion, Greece, Technical Report, 2017. [Online]. Available: <https://www.enisa.europa.eu/publications/baseline-security-recommendations-for-iot>
- [27] "Good Practices for Security of Internet of Things in the Context of Smart Manufacturing," European Union Agency for Cybersecurity (ENISA), Heraklion, Greece, Technical Report, 2018. [Online]. Available: <https://www.enisa.europa.eu/publications/good-practices-for-security-of-iot-in-smart-manufacturing>
- [28] "Good Practices for Security of Internet of Things in the Context of Development Cycle," European Union Agency for Cybersecurity (ENISA), Heraklion, Greece, Technical Report, 2018. [Online]. Available: <https://www.enisa.europa.eu/publications/good-practices-for-security-of-iot-in-the-context-of-development-cycle>
- [29] "Cybersecurity and Resilience of Smart Cars — Good Practices," European Union Agency for Cybersecurity (ENISA), Heraklion, Greece, Technical Report, 2019. [Online]. Available: <https://www.enisa.europa.eu/publications/cybersecurity-and-resilience-of-smart-cars>
- [30] "Port Cybersecurity — Good Practices for Cyber Risk Management in the Maritime Sector," European Union Agency for Cybersecurity (ENISA), Heraklion, Greece, Technical Report, 2019. [Online]. Available: <https://www.enisa.europa.eu/publications/port-cybersecurity>
- [31] "Space Threat Landscape," European Union Agency for Cybersecurity (ENISA), Heraklion, Greece, Technical Report, 2022. [Online]. Available: <https://www.enisa.europa.eu/publications/space-threat-landscape>
- [32] "Threat Landscape for Smart Home Environments," European Union Agency for Cybersecurity (ENISA), Heraklion, Greece, Technical Report, 2020. [Online]. Available: <https://www.enisa.europa.eu/publications/enisa-threat-landscape-for-smart-home-environments>
- [33] "Security and Resilience of Smart Home Environments," European Union Agency for Cybersecurity (ENISA), Heraklion, Greece, Technical Report, 2020. [Online]. Available: <https://www.enisa.europa.eu/publications/security-and-resilience-of-smart-home-environments>
- [34] "Ad-hoc and Sensor Networking for M2M Communications — Threat Landscape and Good Practices Guide," European Union Agency for Cybersecurity (ENISA), Heraklion, Greece, Technical Report, 2016. [Online]. Available: <https://www.enisa.europa.eu/publications/ad-hoc-and-sensor-networking-for-m2m>

Emulación Adversaria Adaptativa aplicada a Infraestructuras Críticas y Redes IIoT

Javier Parada

Universidad de Málaga, Málaga, Spain

javierparada@uma.es

Eurecat, Centre Tecnològic de Catalunya,

Barcelona, Spain

javier.parada@eurecat.org

Mario Reyes

Eurecat, Centre Tecnològic de Catalunya

Barcelona, Spain

mario.reyes@eurecat.org

Javier Lopez

Universidad de Málaga

Málaga, Spain

javierlopez@uma.es

Resumen—Los ataques dirigidos a infraestructuras críticas y entornos industriales han experimentado un incremento significativo en la última década, impulsados por actores internacionales cada vez más sofisticados, atraídos por los incentivos económicos y el alto impacto asociado a estos sectores. En este contexto, este trabajo presenta una solución basada en Emulación Adversaria (EA), que propone la ejecución de tácticas de ataque adaptadas dinámicamente a la infraestructura objetivo. La propuesta mantiene un balance entre la capacidad de imitación del comportamiento del adversario emulado y la adaptabilidad a las características inherentes del entorno a atacar. Todo esto, guiado mediante técnicas de Machine Learning (ML) y simulación de infraestructuras industriales, que permiten a la Inteligencia Artificial (IA) realizar un entrenamiento eficiente con el que aprender de esta y de sus debilidades.

Index Terms—Emulación Adversaria Adaptativa, Infraestructuras Críticas, Caza de Amenazas

Tipo de contribución: Investigación ya publicada [1]

I. INTRODUCCIÓN

El estado actual de la ciberseguridad presenta una preocupación cada vez mayor, especialmente en sectores estratégicos y críticos para la sociedad. Los entornos industriales han evolucionado hacia escenarios altamente interconectados que, aunque han aportado beneficios significativos, también han ampliado la superficie de exposición y los desafíos asociados, atrayendo a adversarios cada vez más sofisticados. Estos se centran en sectores críticos como energía, movilidad y salud, por su alto impacto ante disrupciones. A pesar de los esfuerzos de securización, estos entornos afrontan un nivel de exposición sin precedentes, como demuestran múltiples incidentes recientes: ataques contra infraestructuras energéticas en Ucrania [2] u operaciones contra instalaciones nucleares en Irán [3], atribuidos a actores estatales avanzados.

Esto ha impulsado que nuevos enfoques centrados en la proactividad emerjan con fuerza de entre las técnicas defensivas, destacando entre ellas la Emulación Adversaria (EA). La EA se basa en la ejecución controlada de las Tácticas Técnicas y Procedimientos (TTP) de un adversario con un perfil concreto, con el objetivo de reproducir comportamientos atribuibles a dicho actor mientras se evalúan las capacidades defensivas y los mecanismos de detección de una organización. Tradicionalmente, software como MITRE Caldera [4], han potenciado el desarrollo de la EA, permitiendo reproducir campañas mediante la concatenación automatizada de técnicas ejecutadas por agentes en entornos objetivo.

Sin embargo, estas técnicas tienden a obviar un aspecto fundamental, la adaptabilidad de los TTP al entorno específico en el que se ejecutan. Con el objetivo de abordar esta limitación, nuestro trabajo [1], introduce por primera vez el concepto de Emulación Adversaria Adaptativa (EAA). Esta técnica propone la adaptación de los TTP de los actores mediante Machine Learning (ML), manteniendo un equilibrio entre la similitud del comportamiento del adversario y el rendimiento operativo del ataque.

II. EMULACIÓN DE LA INFRAESTRUCTURA

La emulación de la infraestructura representa un elemento fundamental dentro de la EAA en el contexto de las infraestructuras críticas, dado a que la ejecución de un ataque real sobre estas resulta inviable debido al riesgo de interrupción de servicios esenciales y estratégicos. Con este propósito, numerosos estudios han tomado diferentes estrategias, entornos de prueba controlados, modelos matemáticos [5] y probabilísticos, uso de Máquinas Virtuales (MV) [6] o en el caso de [1] el uso de Digital Twin (DT) [7]. En el trabajo, la ejecución de los ataques se realiza sobre un emulador virtual que representa una infraestructura física real. Ambos sistemas se encuentran sincronizados de forma bidireccional en forma de DT. Los cambios que se producen en la infraestructura física se reflejan en el DT, mientras que este último envía información de actualización y recomendaciones de mitigación de vulnerabilidades, detectadas mediante el análisis de los ataques recibidos.

Con el objetivo de agilizar el entrenamiento de los agentes, se desarrolla un entorno simulado basado en un modelo probabilístico. Dicho modelo se genera a partir del análisis de ataques independientes sobre cada uno de los nodos del DT. Este modelo permite estimar la probabilidad de que un adversario comprometa un nodo en función de las decisiones tomadas durante el ataque y de la interfaz de red desde la que se origina. Un reto del sistema es verificar si la red ha sido comprometida, lo que requiere una infraestructura con características industriales realistas. Para ello, la topología sigue una distribución *power-law* [8] y los nodos se agrupan según su rol, conforme a principios de teoría de control [9] y dominancia estructural [10]. Cada nodo se pondera por su grupo y centralidad, estableciéndose un umbral que determina cuándo la infraestructura se considera vulnerada.

III. MODELADO DEL COMPORTAMIENTO

El enfoque propuesto modela un atacante que mantiene un balance en la adaptación a la infraestructura con una táctica específica basada en el compromiso de nodos centrales. Dado que la red sigue una distribución *power-law*, estos nodos ofrecen una ventaja estratégica al facilitar la propagación hacia zonas periféricas y el establecimiento de posterior persistencia. Con ese objetivo se ha utilizado un algoritmo basado en Reinforcement Learning (RL) con una función de recompensa que se activa de forma positiva cuando el atacante consigue vulnerar el sistema, es decir, cuando supera el umbral descrito en la Sección II. Simultáneamente, los *inputs* del modelo se simplifican al máximo para evitar que aprenda características adicionales de la red, limitando estas a la posición del adversario y aliados, así como a los nodos disponibles y los ya comprometidos, favoreciendo el desarrollo de la estrategia definida.

Este modelo selecciona los nodos a atacar y aplica un vector de ataque predefinido basado en escaneo de servicios, explotación y propagación. El agente dispone de una base de datos de vulnerabilidades y exploits que se actualiza automáticamente, permitiendo detectar fallos dinámicamente y ejecutando un algoritmo de explotación no determinista. Este comportamiento se ilustra en la Figura 1, donde se muestra el grafo generado y la probabilidad de que el agente infecte cada nodo basado en las estadísticas de ataque, representando los colores más oscuros los valores máximos de probabilidad.




Figura 1. Topología de red y prioridades de ataque

IV. EXPERIMENTOS Y RESULTADOS

Los experimentos se desarrollan en dos infraestructuras diferentes. La primera, en el simulador mencionado en la Sección II. Este entorno sirve para entrenar el modelo atacante y para analizar el rendimiento del atacante a lo largo de una distribución amplia de partidas. En concreto, siendo V el conjunto de nodos del sistema, se generan entornos industriales de tamaños 10, 20, 50 y 100, con el objetivo de evaluar el rendimiento a diferentes grados de complejidad de red. Los resultados visibles en la Tabla I muestran cómo el modelo consigue una tasa de victorias clara a partir de $|V| \geq 50$, momento a partir del cual la complejidad de la red ofrece un margen efectivo al agente para priorizar nodos críticos dentro de la infraestructura y hacerse con la victoria. Se observan además anomalías en el ratio de victorias en favor del defensor en topologías estrelladas de alta densidad, donde atacante y defensor alcanzan un equilibrio de Nash en torno a la conquista de un nodo central. No obstante, el incremento

de la complejidad de la red a partir de $|V| = 100$ provoca la desaparición de este fenómeno.

Tabla I
DISTRIBUCIÓN DE MEDIAS DE VICTORIAS DEL ADVERSARIO

$ V $	Atacante	Defensor	Empates	Defensa	Anomalías
10	~ 49 %	~ 49 %	~ 2 %	~ 51 %	✗
20	~ 55 %	~ 41 %	~ 4 %	~ 51 %	✓
50	~ 63 %	31 %	~ 6 %	~ 51 %	✓
100	> 80 %	< 20 %	~ 4 %	< 20 %	✗

Para validar que la aproximación del modelo es representativa, estas mismas pruebas se ejecutaron directamente sobre el DT. Debido al elevado coste computacional que conllevan, dichas pruebas se realizaron únicamente en el entorno en el que el simulador arrojó los mejores resultados, es decir, aquellos con $|V| = 100$. Los resultados muestran un ratio de victorias superior al 70 %, ligeramente inferior al predicho en la simulación, pero satisfactorio en cuanto al rendimiento del adversario.

V. CONCLUSIONES

Este estudio presenta un enfoque innovador y eficaz para el desarrollo adaptativo de la EA. Asimismo, aborda desafíos como el elevado coste computacional asociado a la ejecución de pruebas, incluso en sistemas emulados como los DTs, proponiendo una metodología basada en la generación de simuladores basados en estadísticas obtenidas del propio DT.

AGRADECIMIENTOS

El primer autor es estudiante del programa de becas de doctorado «Vicente López» de Eurecat.

REFERENCIAS

- [1] J. Parada, C. Alcaraz, J. Lopez, J. Caubet, and R. Román, "Digital twin for adaptive adversary emulation in iiot control networks," in *European Symposium on Research in Computer Security*. Springer, 2025, pp. 423–442.
- [2] A. Greenberg, "Russia's cyberwar on ukraine is a blueprint for what's to come," *Wired*, 2017, accessed: 2026-02-16. [Online]. Available: <https://www.wired.com/story/russian-hackers-attack-ukraine/>
- [3] K. Zetter, "Countdown to zero day: Stuxnet and the launch of the world's first digital weapon," *Wired*, 2014, accessed: 2026-02-16. [Online]. Available: <https://www.wired.com/2014/11/countdown-to-zero-day-stuxnet/>
- [4] MITRE Corporation, "Caldera: A scalable automated adversary emulation platform," <https://caldera.mitre.org/>, 2024, accessed: 2026-02-16.
- [5] A. Bhattacharya, T. Ramachandran, S. Banik, C. P. Dowling, and S. D. Bopardikar, "Automated adversary emulation for cyber-physical systems via reinforcement learning," in *2020 IEEE International Conference on Intelligence and Security Informatics (ISI)*. IEEE, 2020, pp. 1–6.
- [6] A. B. Ajmal, M. A. Shah, C. Maple, M. N. Asghar, and S. U. Islam, "Offensive security: Towards proactive threat hunting via adversary emulation," *IEEE Access*, vol. 9, pp. 126 023–126 033, 2021.
- [7] C. Alcaraz and J. Lopez, "Digital twin: A comprehensive survey of security threats," *IEEE Communications Surveys & Tutorials*, vol. 24, no. 3, pp. 1475–1503, 2022.
- [8] C. Palmer and J. Steffan, "Generating network topologies that obey power laws," in *Globecom '00 - IEEE Global Telecommunications Conference. Conference Record (Cat. No.00CH37137)*, vol. 1, 2000, pp. 434–438 vol.1.
- [9] J. Kneis, D. Mölle, S. Richter, and P. Rossmanith, "Parameterized power domination complexity," *Information Processing Letters*, vol. 98, no. 4, pp. 145–149, 2006.
- [10] C. Alcaraz, E. E. Miciolino, and S. Wolthusen, "Multi-round attacks on structural controllability properties for non-complete random graphs," in *Information Security: 16th International Conference, ISC 2013, Dallas, Texas, November 13-15, 2013, Proceedings*. Springer, 2015, pp. 140–151.

Análisis comparativo de técnicas de engaño en OT: Honeypots Modbus deterministas vs. generativo basado en LLM

Carlos Riggio Diéguez
Gradiant
Vigo, España
criggio@gradient.org

Araceli Goiriz Seoane
Gradiant
Vigo, España
agoiriz@gradient.org

Resumen—En el marco de la Industria 4.0, la creciente convergencia entre las tecnologías de la información (IT) y la operación (OT) ha expandido drásticamente la superficie de exposición en infraestructuras críticas, exponiendo vulnerabilidades inherentes en protocolos industriales estándar como Modbus TCP. Este trabajo aborda dicha problemática mediante el diseño, implementación y evaluación comparativa de dos arquitecturas de defensa activa basadas en *honeypots*. Se confronta una aproximación determinista clásica frente a una solución híbrida innovadora que integra *Large Language Models* (LLMs) para la generación dinámica de respuestas. El estudio analiza el desempeño de ambas estrategias evaluando métricas clave como la integridad protocolaria, la latencia de respuesta, la viabilidad operativa y la eficacia en el engaño frente a ciberataques.

Index Terms—Ciberseguridad Industrial, Honeypot, Modbus TCP, LLMs, OT.

Tipo de contribución: Investigación

I. INTRODUCCIÓN

En el panorama digital actual, las empresas del sector industrial se enfrentan a un conjunto de desafíos de ciberseguridad sin precedentes. Tradicionalmente, estos entornos se han basado en la Tecnología Operativa (OT), definida como el hardware y software que detecta o provoca cambios en procesos físicos mediante la monitorización y el control directo de dispositivos físicos [1]. Sin embargo, la creciente conectividad entre estos sistemas OT y las redes de datos corporativas, impulsada por la convergencia con las Tecnologías de la Información (IT) y paradigmas como el Internet de las Cosas (IoT) y el Internet Industrial de las Cosas (IIoT), ha aumentado significativamente la superficie de exposición a diversas amenazas y ataques en línea. Desde intrusiones maliciosas hasta intentos de sabotaje, estas amenazas pueden tener consecuencias graves, que van desde la interrupción de la producción hasta el daño reputacional o la pérdida de datos confidenciales.

La relevancia de esta problemática se refleja en las estadísticas recientes y en la atención recibida desde las políticas públicas. Según instituciones europeas y nacionales, como se recoge en la Estrategia de Seguridad Nacional 2021 [2], los ciberataques son cada vez más sofisticados. En España, los delitos informáticos crecieron un 22,7 % solo en 2022, alcanzando los 374.737 casos, de los cuales casi el 90 % fueron fraudes digitales [3]. Ante este escenario, la adopción de medidas de ciberdefensa se convierte en una prioridad para salvaguardar las infraestructuras críticas.

Una de las metodologías más eficaces para la protección en estos entornos es el despliegue de *honeypots*. Un *honeypot* se define como un sistema diseñado específicamente para engañar a un atacante, haciéndole creer que está interactuando con un entorno real, cuando en realidad es un sistema aislado sin valor productivo para el propietario.

La implementación de *honeypots* ofrece beneficios significativos en tres áreas clave de la seguridad:

- **Prevención:** Actúan como métodos de engaño, evitando que los sistemas reales sean comprometidos.
- **Detección:** Son altamente eficaces para identificar intrusos en tiempo real. A diferencia de los sistemas de detección de intrusos tradicionales que generan grandes volúmenes de datos, los *honeypots* tienen una baja tasa de falsos positivos, ya que cualquier tráfico dirigido a ellos se considera, por definición, malicioso o no autorizado.
- **Respuesta:** Facilitan la recopilación de información forense crucial (comandos ejecutados, herramientas utilizadas, identidad del atacante) necesaria para responder eficazmente a incidentes, incluso si el atacante intenta borrar sus huellas.

Existen diferentes tipos de *honeypots* clasificados según su propósito y su nivel de interacción. Los de baja interacción emulan servicios básicos y son fáciles de desplegar pero limitados en la información que recogen; mientras que los de alta interacción simulan sistemas operativos reales, ofreciendo una visión detallada del comportamiento del atacante a cambio de un mayor riesgo y coste de mantenimiento.

Dada la necesidad de proteger las comunicaciones industriales, este trabajo se centra en el protocolo Modbus, un estándar creado a finales de los años 70 para la comunicación entre PLCs que sigue siendo ampliamente utilizado hoy en día. Específicamente, nos enfocamos en Modbus TCP, una variante diseñada para aprovechar las infraestructuras de red Ethernet existentes, encapsulando las tramas Modbus dentro de paquetes TCP y operando comúnmente en el puerto 502.

Debido a la sencillez de su implementación y a la ausencia de costes por licencia, Modbus TCP cuenta con una vasta base instalada histórica, manteniéndose como uno de los protocolos heredados más ubicuos en infraestructuras industriales.

A pesar de su flexibilidad y uso extendido para la comunicación *peer-to-peer* entre dispositivos, Modbus TCP presenta graves carencias de seguridad por diseño. El protocolo no

dispone de mecanismos para proteger la confidencialidad ni garantizar la integridad de los mensajes, lo que lo hace vulnerable a modificaciones maliciosas indetectables.

Entre las debilidades críticas que justifican el desarrollo de *honeypots* específicos para este protocolo destacan:

- Falta de autenticación: Permite la ejecución no autorizada de comandos si el atacante tiene acceso a la red.
- Ausencia de mecanismos anti-repudio y anti-replay: Facilita ataques de repetición donde un actor malicioso puede capturar y reenviar comandos legítimos para engañar al sistema.
- Susceptibilidad a ataques de Denegación de Servicio (DoS) y *Man-in-the-Middle*: Un atacante puede inundar los dispositivos con mensajes o interceptar las comunicaciones para alterar el funcionamiento de la red industrial.

Recientemente, la literatura ha comenzado a explorar la integración de la Inteligencia Artificial Generativa en el ámbito del ciberengaño industrial. Trabajos pioneros como *LLMPot* [4] han demostrado que es posible generar tráfico Modbus y S7comm entrenando (*fine-tuning*) modelos especializados a nivel de byte para evitar los problemas inherentes a la tokenización de texto. Sin embargo, dicho trabajo no aborda la viabilidad de emplear modelos fundacionales comerciales listos para usar sin requerir procesos previos de entrenamiento intensivo.

El objetivo principal de este trabajo es el diseño, implementación y evaluación comparativa de un *honeypot* especializado en el protocolo Modbus TCP, abordado desde dos paradigmas de desarrollo diferentes. En primer lugar, se realiza una implementación basada en técnicas de simulación tradicionales, donde la generación de tráfico y la lógica de respuesta se rigen por reglas deterministas y patrones estáticos. En segundo lugar, se propone una arquitectura híbrida innovadora que integra *Large Language Models* como motor lógico para la toma de decisiones y la generación dinámica de respuestas. Finalmente, se establece una comparativa funcional entre ambas implementaciones para analizar el impacto de la Inteligencia Artificial Generativa en el realismo del entorno simulado, su viabilidad operativa y su eficacia frente a las técnicas de defensa convencionales.

II. METODOLOGÍA

Esta sección detalla el proceso de diseño y desarrollo de las dos variantes de *honeypot* propuestas. El enfoque metodológico comienza con la definición de una arquitectura común y escalable, continúa con la implementación estricta del protocolo Modbus (enfoque determinista) y culmina con la adaptación de esta infraestructura para integrar Inteligencia Artificial Generativa (enfoque híbrido).

II-A. Arquitectura General del Sistema

El diseño del *honeypot* se ha concebido priorizando la escalabilidad, con el objetivo de soportar múltiples protocolos de comunicación industrial simultáneamente. Para ello, se ha implementado una Arquitectura Hexagonal [5] basada en la técnica de *Vertical Slicing* (Figura 1).

Bajo este enfoque, el sistema se divide en módulos funcionales independientes, cada uno de estos estructurados internamente en tres capas que definen su funcionamiento:

- Aplicación: Capa encargada de la orquestación y el lanzamiento de los servicios.
- Dominio: Define las reglas de negocio y las especificaciones básicas del comportamiento de los *honeypots*.
- Infraestructura: Contiene la implementación técnica concreta de los protocolos. Es en esta capa donde reside la lógica específica.




Figura 1. Arquitectura Hexagonal con Vertical Slicing

Para la emulación de la memoria del PLC y la persistencia del estado, se implementó una base de datos ligera utilizando SQLite [6]. El esquema relacional se estructura en torno a una tabla única constituida por los atributos Dirección, Tipo y Valor, diseñada con restricciones de integridad acordes a la naturaleza del objeto Modbus. Específicamente, el campo Tipo condiciona el formato admisible del campo Valor: para los registros, se almacenan valores exclusivamente numéricos, mientras que para las bobinas, los valores se restringen estrictamente a estados binarios.

Finalmente, para facilitar el análisis posterior, los logs y las sesiones registradas se centralizan en una instancia de OpenSearch [7]. Esta información se estructura e indexa clasificándola según el protocolo de red a través del cual se recibió la intrusión.

II-B. Implementación Determinista: El Estándar Modbus

La primera implementación del *honeypot* es de naturaleza determinista. Su objetivo es replicar el comportamiento exacto de un PLC real mediante programación estricta. Para lograr esto, fue necesario realizar ingeniería inversa sobre el protocolo Modbus TCP y definir las estructuras binarias que el software debe construir byte a byte.

El protocolo define una Unidad de Datos de Protocolo (PDU) independiente de la capa de comunicación. Al mapearse sobre TCP/IP, se añaden campos adicionales formando la Unidad de Datos de Aplicación (ADU) [8], tal como se muestra en la Figura 2, conteniendo el Código de Función y el campo de Datos, cuya estructura varía dinámicamente según la operación solicitada.




Figura 2. Estructura del ADU Modbus

En Modbus TCP, la cabecera MBAP (*Modbus Application Protocol*) reemplaza el checksum del serial e introduce:

- Transaction ID: Identificador único para emparejar petición y respuesta.

- Protocol ID: Siempre 0 para Modbus.
- Length: Longitud de los bytes restantes.
- Unit ID: Identificador del esclavo.

El honeypot determinista implementa las reglas para generar las respuestas exactas según las siguientes estructuras identificadas:

1. Lectura y escritura de registros: Las operaciones de registros manipulan datos de 16 bits. La Tabla I muestra la simetría en la escritura, mientras que la lectura (Tablas II y III) exige devolver un conteo de bytes preciso.

Tabla I
ESTRUCTURA: ESCRITURA DE REGISTRO (PET/RESP)

ID Trans	ID Prot	Long	Unidad	Func	Dir	Valor

Tabla II
ESTRUCTURA: LECTURA DE REGISTRO (PETICIÓN)

ID Trans	ID Prot	Long	Unidad	Func	Dir	Cant

Tabla III
ESTRUCTURA: LECTURA DE REGISTRO (RESPUESTA)

ID Trans	ID Prot	Long	Unidad	Func	Bytes	Valor

2. Bobinas: Siguen una estructura análoga a los registros pero operan a nivel de bit, empaquetando 8 bobinas por byte de datos. (Tablas omitidas por brevedad, siguen estructura análoga a Tablas I-III).
3. Escritura Múltiple: Este es el caso más complejo debido a la variabilidad de la carga útil (Tabla IV). El honeypot debe ser capaz de parsear dinámicamente el campo 'Bytes' y 'Valores' para extraer la información y almacenarla en la base de datos.

Tabla IV
PETICIÓN ESCRITURA MÚLTIPLE

ID Trans	ID Prot	Long	Unidad	Func	Dir	Cant	Bytes	Valores

Esta implementación determinista sirve como línea base para evaluar el desempeño y la corrección del honeypot basado en IA.

II-C. Implementación Generativa

Partiendo de la arquitectura general y con el conocimiento de las estructuras de paquetes definidas anteriormente, se desarrolló una segunda variante del honeypot. Esta implementación sustituye la lógica determinista rígida por una Arquitectura Híbrida (Figura 3) que integra la eficiencia del procesamiento de red convencional con la capacidad de razonamiento semántico de los LLMs. A diferencia de la simulación determinista, delega la interpretación del protocolo y la generación de respuestas dinámicas a un motor de Inteligencia Artificial.

Para la implementación de la arquitectura se utilizó el modelo gpt-4o-mini de OpenAI [9] en ambos componentes. Este modelo destaca por su optimización en latencia y costes, superando a versiones previas en tareas de razonamiento estructurado.

La elección se justifica principalmente por tres factores: su baja latencia permite procesar tramas Modbus casi en tiempo real; su capacidad para seguir instrucciones estrictas asegura una interpretación correcta de formatos JSON; y su eficiencia económica, combinada con una amplia ventana de contexto, facilita la ejecución de pruebas masivas sin incurrir en costes elevados.




Figura 3. Arquitectura general del Honeypot LLM

No obstante, la dependencia exclusiva de un modelo generativo para la totalidad de la pila de comunicaciones introduce corrupción en el procesamiento de tramas binarias. Por ello, el uso del LLMs se complementa con lógica programática. Esta capa actúa como un *middleware* determinista que asiste al modelo en las tareas donde estos presentan debilidades.

Con el objetivo de maximizar la precisión y la mantenibilidad del sistema, se ha optado por dividir la lógica de Inteligencia Artificial en dos instancias diferentes. Esta decisión de diseño responde al principio de *Separation of Concerns* (SoC), evitando sobrecargar un único contexto con tareas opuestas de análisis de una solicitud modbus y de generación de una respuesta.

El flujo de procesamiento se desacopla en dos modelos especializados que operan de forma secuencial:

LLM Receptor: Analizador de Peticiones

Este componente actúa como un decodificador cuya función principal es transformar el paquete recibido en una estructura de datos semántica que describa la acción solicitada. Para profundizar en su implementación técnica, el análisis se estructura en torno a tres pilares fundamentales: la lógica operativa del LLM, la especificación de los formatos de datos y el diseño estratégico del prompt.

Lógica Operativa

El modelo no interactúa directamente con el socket de red. Un módulo de pre-procesamiento programático realiza la extracción inicial crítica mediante una función de parseo del paquete binario. Este proceso incluye:

- *Desempaquetado Binario*. Se leen los campos de longitud fija del encabezado MBAP (Transaction ID, Protocol ID, Length, Unit ID) y el código de función.
- *Conversión Hexadecimal*. Transforma el cuerpo de la PDU (Protocol Data Unit) de bytes crudos a una cadena hexadecimal.

Este paso convierte datos binarios ambiguos en un formato de texto estructurado, permitiendo que el LLM se

concentre exclusivamente en la interpretación lógica de la carga útil. Véase este flujo en la Figura 4.




Figura 4. Arquitectura LLM analizador de paquetes

Diseño del Prompt

El prompt del sistema (Apéndice A) se ha diseñado bajo el rol de un analizador determinista de Modbus TCP, estructurado para forzar un comportamiento de máquina de estados. Incluye:

- **Algoritmos de Decodificación.** Para funciones complejas como la escritura múltiple (FC 15 y 16), se incluyen instrucciones algorítmicas paso a paso, como ignorar los caracteres de metadatos iniciales y segmentar el resto en bloques fijos.
- **Segmentación Visual.** Se proporcionan ejemplos visuales de cómo dividir la cadena hexadecimal para evitar errores de alineación.
- **Salida Estricta.** Se impone una restricción negativa fuerte prohibiendo cualquier texto explicativo, asegurando que la respuesta sea únicamente un objeto JSON válido.

Formato de Datos

La comunicación entre el pre-procesador Python y el modelo LLM se estandariza mediante esquemas JSON estrictos, garantizando la interoperabilidad.

- **Vector de Entrada:** El modelo recibe un objeto JSON que abstrae la trama de red. Los campos críticos son:
 - **function_code (int):** El identificador numérico de la operación Modbus.
 - **data_hex (string):** La carga útil convertida a una cadena hexadecimal. Este campo es vital para las funciones de escritura compleja, ya que contiene los valores embebidos que el modelo debe extraer.
 - **transaction_id (int) y unit_id (int):** Metadatos de trazabilidad de la sesión TCP.
 - **address y quantity (int, opcionales):** Valores precalculados por el código para operaciones simples

de lectura, sirviendo como contexto de apoyo para el modelo.

- **Vector de Salida:** La respuesta generada por el LLM es un objeto JSON enriquecido que normaliza la intención del atacante. Su estructura varía dinámicamente según la acción detectada:
 - **action (string):** La interpretación textual de la intención.
 - **registers/coils (array de objetos):** Para operaciones de escritura, el modelo devuelve una lista desglosada donde cada elemento contiene la tupla de dirección y valor, resultado de la segmentación algorítmica de la cadena hexadecimal.
 - **start_address y quantity:** Para operaciones de lectura, confirma el rango de memoria solicitado.

LLM Generador: Constructor de Respuestas

Este modelo es responsable de generar la secuencia de bytes hexadecimales que conforman la PDU de respuesta, basándose en los datos del estado simulado del PLC. Para profundizar en su implementación técnica, el análisis se estructura en torno a los mismos tres pilares fundamentales.

Lógica Operativa

La eficiencia del sistema recae en un uso selectivo del modelo, complementado por lógica programática:

- **Bypass Determinista.** Para operaciones de escritura (FC 5, 6, 15, 16), donde la respuesta es un eco estático, el sistema omite el LLM y construye el paquete instantáneamente mediante código, eliminando latencia.
- **Pre-procesamiento de Datos.** Para lecturas (FC 1, 2, 3, 4), el sistema formatea los valores numéricos de la base de datos a cadenas hexadecimales de longitud fija antes de enviarlos al modelo, simplificando la tarea a un problema de ensamblaje.
- **Post-procesamiento.** El modelo solo genera la PDU. El código calcula la longitud final y añade el encabezado MBAP correcto antes de enviar el paquete por la red.

Véase este flujo en la Figura 5.

Diseño del Prompt

El prompt (Apéndice A) asigna el rol de codificador de bytes de bajo nivel, priorizando la precisión técnica sobre la creatividad. Sus características principales son:

- **Distinción Tipológica.** Define reglas estrictas para diferenciar entre registros (4 caracteres hexadecimales) y bobinas (bytes compactados de 2 caracteres).
- **Aprendizaje por Contraste.** Incluye una tabla de comparación visual que muestra explícitamente errores comunes de relleno frente a la codificación correcta para prevenir alucinaciones en la longitud de los datos.
- **Algoritmo de Decisión.** Instruye al modelo para seleccionar el modo de codificación adecuado basándose en el código de función recibido.

Formato de Datos

De manera análoga al analizador, la interfaz para el generador de respuestas se ha diseñado para minimizar la carga computacional del modelo, entregando los datos preformateados para facilitar el ensamblaje final.

- **Vector de Entrada:** El objeto JSON enviado al modelo contiene los parámetros necesarios para construir la




Figura 5. Arquitectura LLM generador de respuesta

respuesta, diferenciando explícitamente el formato de los datos según la operación:

- `function_code` (int): Determina el algoritmo de codificación a utilizar.
- `quantity` (int): Utilizado por el modelo para calcular el campo de conteo de bytes (*Byte Count*) de la cabecera Modbus.
- `data_hex` (lista de strings): Campo exclusivo para registros (FC 03, 04). Contiene los valores extraídos de la base de datos y pre-convertidos por Python a formato hexadecimal de 4 caracteres (e.g., "00FF"). Esto elimina la necesidad de que el LLM realice conversiones aritméticas complejas.
- `data` (lista de enteros): Campo exclusivo para bobinas (FC 01, 02). Contiene una lista de estados booleanos (0 o 1) que el modelo debe empaquetar y compactar a nivel de bit.
- **Vector de Salida:** Dado que la complejidad lógica se resuelve en la entrada, la salida se ha simplificado al máximo para reducir la latencia de inferencia:
 - `pdu_hex` (string): Una única cadena hexadecimal que representa la PDU completa de respuesta. El código Python simplemente convierte esta cadena a bytes y le añade la cabecera TCP (MBAP) antes de enviarla a la red.

III. RESULTADOS

Este capítulo presenta la validación experimental de las arquitecturas propuestas. En una primera fase, se verifica la funcionalidad base de ambos sistemas, demostrando su capacidad para operar como dispositivos Modbus TCP estándar. Posteriormente, se realiza un análisis comparativo sobre la calidad de la interacción y la robustez de cada enfoque.

III-A. Validación Funcional

Antes de evaluar las capacidades avanzadas de engaño, se sometió a ambos prototipos a pruebas de conectividad y reconocimiento para garantizar que cumplen con los requisitos mínimos de un servicio industrial expuesto.

III-A1. Reconocimiento de Red: Para garantizar que el señuelo sea indistinguible de un dispositivo industrial real durante las fases de reconocimiento, se diseñó un mecanismo específico de respuesta ante escaneos de red. Es importante destacar que esta funcionalidad se implementó de manera idéntica tanto en la arquitectura del honeypot tradicional como en la basada en LLM, ubicándose en la capa de transporte para asegurar una consistencia total en la visibilidad del servicio.

El sistema debe ser capaz de gestionar diferentes tipos de sondeo para evitar ser detectado como una simulación. El escaneo más básico, conocido como TCP SYN scan o técnica *half-open*, inicia una conexión enviando un paquete SYN pero no completa el proceso de saludo (handshake), esperando simplemente una respuesta del puerto. Sin embargo, herramientas avanzadas como Nmap [10] ejecutan escaneos más profundos que completan el saludo de tres vías (TCP 3-way handshake) para intercambiar datos y determinar la versión del servicio, utilizando comandos como `-sV`.

Para replicar fielmente el comportamiento de un PLC real ante un escaneo de versión, se realizó un análisis de ingeniería inversa sobre el dispositivo físico monitoreando el tráfico con Wireshark [11]. Se observó que, tras establecer la conexión, el atacante envía un paquete de datos PSH/ACK con la carga útil hexadecimal `0d0a0d0a`. En respuesta, el PLC legítimo devuelve invariablemente un paquete conteniendo la secuencia hexadecimal `0d0a0d0a0003008001`, tras lo cual el escáner cierra la conexión.

Basándose en este hallazgo, se programó una regla estática en el servidor de ambos honeypots. Independientemente de la lógica de procesamiento posterior, el servidor inspecciona los primeros bytes recibidos. Si la trama entrante coincide con el valor hexadecimal `0d0a0d0a`, el sistema omite el procesamiento Modbus estándar y devuelve directamente la firma `0d0a0d0a0003008001`.

Esta implementación permite satisfacer la primera prueba de sondeo del escáner. Al recibir la respuesta esperada, la herramienta de ataque da por válida la identificación del servicio y no ejecuta pruebas adicionales más complejas, garantizando así la credibilidad del sistema sin consumir recursos de computación innecesarios. Véase esta solución en la Figura 6.

```

(!envy) oripdu - /slimes/gpt-4o-mini-honeypot (/lib/modbus) $ nmap -sV 127.0.0.1 -p 502
Starting Nmap 7.94SVN ( https://nmap.org ) at 2024-01-08 06:48 CET
Nmap scan report for localhost (127.0.0.1)
Host is up (0.00027s latency).

PORT      STATE SERVICE VERSION
502/tcp    open  modbus  Modbus TCP

Service detection performed. Please report any incorrect results at https://nmap.org/report/
Nmap done: 1 IP address (1 host up) scanned in 0.45 seconds

```

Figura 6. Escaneo NMAP exitoso

III-A2. Interacción con el Protocolo y Registro de Logs: Para validar la lógica operativa en ambas arquitecturas, se diseñaron y ejecutaron scripts de prueba automatizados. La metodología de validación se basó en un ciclo de interacción secuencial de escritura-verificación.

En una primera etapa, se envían solicitudes de escritura a direcciones específicas para evaluar la capacidad del *honeypot* de procesar, aceptar y responder a tramas Modbus válidas. Posteriormente, se ejecutan consultas de lectura sobre esas mismas direcciones de memoria. Este segundo permite corroborar dos aspectos fundamentales: que el sistema mantiene la persistencia del estado y que la solución es capaz de construir y enviar paquetes de respuesta sintácticamente correctos según el estándar Modbus TCP.

En lo que respecta al *honeypot* tradicional, la implementación basada en *Pymodbus* [12] demostró una respuesta inmediata y conforme al estándar. Las pruebas consistieron en la escritura y lectura de dos registros fijos, complementadas con una secuencia dinámica sobre las bobinas. En esta fase, el script inyecta valores binarios aleatorios (0 o 1) un número indefinido de veces; aunque esta cantidad varía en cada ejecución, en el caso de prueba realizado se ejecutaron 5 iteraciones. Como muestra la Figura 7, el sistema procesó correctamente todo el tráfico y se registraron correctamente todas las interacciones del ataque en el OpenSearch (Figura 8).

```
REQUEST SENT: b'\x00\x00\x00\x00\x00\x00\x00\x00' -- LENGTH: 12
*****MODBUS TCP*****
Transaction Identifier: 48249
Protocol Identifier: 0 --> MODBUS
Length: 6
Unit Identifier: 1
-----PDU-----
Code: 05 -> Write Single Register
Data: b'\x00\x01\x00'
Data Addresses and Values:
Address: 1, Value: 48
*****END TRAMA MODBUS TCP*****
Escribir en el registro holding en la dirección 1 exitosa
REQUEST SENT: b'\x00\x00\x00\x00\x00\x00\x00\x00' -- LENGTH: 12
*****MODBUS TCP*****
Transaction Identifier: 3246
Protocol Identifier: 0 --> MODBUS
Length: 6
Unit Identifier: 1
-----PDU-----
Code: 02 -> Read Single Register
Data: b'\x00\x02\x00'
Data Addresses and Values:
Address: 2, Value: 88
*****END TRAMA MODBUS TCP*****
```

Figura 7. Tradicional, escritura y lectura de registros



Figura 8. Tradicional, OpenSearch registros

De forma análoga, el *honeypot* basado en LLM fue sometido a la misma batería de pruebas, arrojando resultados satisfactorios. El sistema procesó correctamente tanto la escritura de registros como la secuencia aleatoria de bobinas, garantizando la conformidad con el protocolo. Como se observa en las Figuras 9 y 10, las respuestas fueron enviadas sin errores y las acciones quedaron debidamente registradas en el OpenSearch.

III-B. Análisis del Comportamiento Diferencial

Una vez validada la funcionalidad base, se procedió a analizar las divergencias operativas y de implementación entre el enfoque determinista y el generativo. El estudio se centró en la dicotomía observada entre la fiabilidad estricta de la programación tradicional y la flexibilidad, acompañada de incertidumbre, de los modelos de lenguaje.

```
REQUEST SENT: b'\x00\x00\x00\x00\x00\x00\x00\x00' -- LENGTH: 12
*****MODBUS TCP*****
Transaction Identifier: 32105
Protocol Identifier: 0 --> MODBUS
Length: 6
Unit Identifier: 1
-----PDU-----
Code: 05 -> Write Single Register
Data: b'\x00\x01\x00'
Data Addresses and Values:
Address: 1, Value: 48
*****END TRAMA MODBUS TCP*****
Escribir en el registro holding en la dirección 1 exitosa
REQUEST SENT: b'\x00\x00\x00\x00\x00\x00\x00\x00' -- LENGTH: 12
*****MODBUS TCP*****
Transaction Identifier: 43997
Protocol Identifier: 0 --> MODBUS
Length: 6
Unit Identifier: 1
-----PDU-----
Code: 02 -> Read Single Register
Data: b'\x00\x02\x00'
Data Addresses and Values:
Address: 2, Value: 88
*****END TRAMA MODBUS TCP*****
Escribir en el registro holding en la dirección 2 exitosa
```

Figura 9. LLM, escritura y lectura de registros 1




Figura 10. LLM, OpenSearch registros

El *honeypot* tradicional destacó por ser una solución estrictamente idempotente, esto implica que, ante una misma entrada, el sistema garantiza invariablemente la misma salida, sin desviaciones ni errores de formato. Las pruebas confirmaron una fiabilidad estructural absoluta, ya que al no existir interpretación probabilística de los datos, la totalidad de los paquetes generados cumplieron estrictamente con el estándar del protocolo.

Por el contrario, la implementación basada en inteligencia artificial presentó un balance distinto entre versatilidad y coste operativo. Como punto positivo, esta arquitectura demostró una gran flexibilidad de configuración, dado que modificar el comportamiento del *honeypot* no requiere reescribir código, sino simplemente alterar las instrucciones en lenguaje natural del sistema.

No obstante, este enfoque conlleva desventajas de infraestructura significativas. La utilización de modelos vía API impone una dependencia estricta de una conexión a internet constante, además de generar un gasto recurrente asociado al modelo de pago por uso. Como alternativa para eliminar estas dependencias externas y los costes variables, se podría optar por la descarga y ejecución de un modelo en local. Sin embargo, esta solución traslada la exigencia al hardware, requiriendo que el dispositivo *honeypot* disponga de recursos computacionales elevados para poder gestionar la inferencia del modelo de forma autónoma.

Además, se observó una disparidad crítica en los tiempos de respuesta. Mientras que el modelo determinista ofrece contestaciones casi inmediatas (Fig 11), replicando la velocidad de un sistema embebido, la solución basada en LLM presentó una latencia media de cuatro segundos por transacción (Fig 12). Este retardo representa una vulnerabilidad en la estrategia de engaño, ya que un atacante podría identificar esta lentitud

anómala como un indicador de que no está interactuando con un dispositivo industrial real.



Figura 11. Tradicional, tiempos de respuesta



Figura 12. LLM, tiempos de respuesta

Desde el punto de vista técnico, se identificó además una limitación crítica en la capacidad de los modelos de lenguaje para manejar operaciones a nivel de bit. Durante las pruebas de escritura de múltiples registros o bobinas, se observó que el modelo sufría dificultades para realizar conteos precisos de bits y gestionar desplazamientos en la trama hexadecimal. El modelo tendía a perder la referencia posicional, confundiendo metadatos de la cabecera con el contenido útil, lo que derivaba en errores de decodificación.

Esta deficiencia demostró que los LLM carecen de una comprensión espacial nativa de las estructuras de datos binarias, tendiendo a procesarlas como texto narrativo. Para solucionar este tipo de errores y garantizar la integridad de la comunicación, es necesario implementar una capa de parseo manual previo. Esta estrategia híbrida, donde el código tradicional pre-procesa la trama binaria para facilitar la labor del modelo, resulta indispensable para mitigar las alucinaciones posicionales y asegurar el correcto funcionamiento del sistema. Véase en la Tabla V un resumen comparativo de ambos enfoques.

Tabla V
RESUMEN COMPARATIVO

Métrica	DETERMINISTA	GENERATIVO
Fiabilidad	Absoluta. Idempotente y cumple estándar.	Variable. Propenso a errores de formato/bits.
Latencia	≈ 0.4 ms (Tiempo Real).	≈ 4 seg.
Dependencia Internet	Nula.	Total (Requiere conexión continua a API).
Coste	Nulo.	Recurrente (Pago por uso/token).

IV. DISCUSIÓN Y CONCLUSIONES

IV-A. Discusión de los Resultados

A la luz de los resultados experimentales obtenidos, se observa que la aplicación de *Large Language Model* en el ámbito de los protocolos industriales presenta un escenario de luces y sombras que condiciona su viabilidad operativa.

IV-A1. La brecha entre tokenización y lógica binaria: Uno de los hallazgos más relevantes de este estudio ha sido la dificultad intrínseca del modelo GPT-4o-mini para interpretar correctamente las tramas binarias de Modbus sin asistencia externa. Esta dificultad se debe en gran medida a los mecanismos de tokenización inherentes a los modelos de lenguaje actuales, los cuales no están optimizados para el

procesamiento matemático y a nivel de byte que requieren los protocolos binarios estandarizados. Esto sugiere que, para entornos OT, la IA Generativa no debe actuar como el *parser* principal del protocolo, sino como un motor lógico de alto nivel, delegando la decodificación estricta a librerías deterministas.

IV-A2. El compromiso entre latencia y credibilidad: La latencia media de tres segundos detectada en el honeypot LLM plantea un desafío crítico para la credibilidad del engaño. En redes industriales reales, los tiempos de respuesta de un PLC se miden en milisegundos. Un atacante experimentado o un script automatizado podría utilizar esta latencia anómala como una firma para identificar el sistema como un señuelo. Por tanto, la solución basada en LLM se perfila como idónea para fases de interacción humana (donde el atacante explora manualmente y tolera retardos) pero resulta menos efectiva contra escaneos automatizados de alta velocidad.

IV-A3. Coste computacional frente a versatilidad: Mientras que el honeypot tradicional requiere horas de desarrollo para añadir nuevas funcionalidades o simular nuevos dispositivos, el sistema basado en LLM demostró una capacidad de adaptación inmediata mediante la modificación del *System Prompt*. Esta versatilidad tiene un coste operativo (pago por token o hardware dedicado) que debe ser evaluado.

IV-B. Conclusiones

El presente trabajo ha demostrado que, si bien la integración de Inteligencia Artificial Generativa en infraestructuras de defensa activa es técnicamente viable, su aplicación directa en protocolos industriales binarios como Modbus TCP no resulta óptima frente a las soluciones tradicionales.

La principal conclusión extraída es que la naturaleza probabilística de los LLM es incompatible con la rigurosidad determinista requerida por la capa de enlace de los protocolos OT. A pesar de implementar arquitecturas híbridas de soporte programático, la complejidad para garantizar la integridad de bit en la generación de paquetes, sumada a la latencia inherente de la inferencia, penaliza la credibilidad del señuelo. Por consiguiente, para la simulación de PLCs y entornos estrictos, el enfoque determinista se mantiene como la opción superior, garantizando respuestas inmediatas, bajo consumo de recursos y coste operativo nulo, factores críticos para un despliegue sostenible a gran escala.

Sin embargo, el valor diferencial de los LLM no reside en la manipulación de bytes, sino en su capacidad de adaptación semántica. La facilidad para modificar el comportamiento del honeypot mediante lenguaje natural valida a esta tecnología como una herramienta poderosa para escenarios donde la interacción se basa en texto. Esto abre una nueva línea de investigación hacia la creación de honeypots de alta interacción para protocolos de gestión como SSH, donde la capacidad del modelo para mantener conversaciones contextuales permitiría superar las limitaciones de los scripts estáticos, ofreciendo un nivel de engaño indistinguible de un operador humano real.

APÉNDICE A

PROMPTS UTILIZADOS PARA LA CONFIGURACIÓN DEL LLM

A continuación, se detallan los *prompts* base utilizados para instruir al modelo gpt-4o-mini durante las pruebas de

evaluación.

Prompt del LLM Receptor

You will receive a single Modbus TCP message already pre-parsed as a JSON/dict with (at least) the following fields:

```
{
  "transaction_id": <int>,
  "protocol_id": <int>,
  "length": <int>,
  "unit_id": <int>,
  "function_code": <int>,
  "address": <int>, # starting address
  "quantity": <int>, # number of registers or coils
  "data_hex": "<hex string>"
}
```

- "data_hex" is a hexadecimal string representing the Modbus PDU data (from the starting address field onwards, in big-endian order).

- You must interpret the message according to the Modbus function code and return a JSON that clearly describes:

- what action is being performed ("action")
- which address or addresses are affected
- which value or values are involved

Always assume big-endian for 16-bit values.

Map the function_code field to a high-level action:

- 3 -> "read_holding_registers"
- 6 -> "write_single_register"
- 1 -> "read_coils"
- 5 -> "write_single_coil"
- 15 -> "write_multiple_coils"
- 16 -> "write_multiple_registers"

Your answer must be a valid JSON object only, with no comments, explanations, or any additional text.

General rules for decoding:

- Function code 6 - write_single_register
 - Decode the value as a 16-bit big-endian integer from the last 4 hex characters of data_hex.
 - Output JSON example:

```
{
  "action": "write_single_register",
  "function_code": 6,
  "unit_id": ...,
  "transaction_id": ...,
  "address": <address>,
  "value": <int>
}
```
- Function code 3 - read_holding_registers
 - Output JSON:

```
{
  "action": "read_holding_registers",
  "function_code": 3,
  "unit_id": ...,
  "transaction_id": ...,
  "start_address": <address>,
  "quantity": <quantity>
}
```
- Function code 5 - write_single_coil
 - Decode the last 4 hex characters to get the 16-bit value (0xFF00=true, 0x0000=false).
 - Output JSON:

```
{
  "action": "write_single_coil",
  "function_code": 5,
  "unit_id": ...,
  "transaction_id": ...,
  "address": <address>,
  "value": true | false
}
```
- Function code 1 - read_coils
 - Output JSON:

```
{
  "action": "read_coils",
  "function_code": 1,
  "unit_id": ...,
  "transaction_id": ...,
  "start_address": <address>,
  "quantity": <quantity>
}
```
- Function code 16 - write_multiple_registers
 - **CRITICAL: HEX STRING SLICING & OFFSET**
 - The "data_hex" string contains a 10-character header. You must NOT read the first 10 characters as values.
 - **Structure:** '[Address(4)] [Quantity(4)] [ByteCount(2)] [PAYLOAD...]'
 - 1. **IGNORE** characters at indices 0 to 9.**
 - 2. **START** reading values strictly from index 10.**
 - 3. The remaining string represents the registers (4 hex chars per register).
 - 4. Split the remaining string into chunks of 4 characters and convert to Decimal Integer (Big-Endian).
 - **Output JSON Schema:**

```
{
  "action": "write_multiple_registers",
  "function_code": 16,
  "transaction_id": <id>,
  "unit_id": <id>,
  "start_address": <addr>,
  "quantity": <qty>,
  "registers": [
    {
      "address": <start_address + 0>,
      "value": <int>,
      ...
    }
  ]
}
```
- Function code 15 - write_multiple_coils
 - Structure: '[Address(4)] [Quantity(4)] [ByteCount(2)] [PAYLOAD...]'
 - 1. **IGNORE** characters at indices 0 to 9.**
 - 2. **START** reading payload STRICTLY from index 10.**
 - 3. For each 2-char Hex Byte in the payload: convert Hex to 8-bit Binary String.
 - **CRITICAL:** REVERSE the binary string and map bits sequentially.
 - **Output JSON Schema:**

```
{
  "action": "write_multiple_coils",
  "function_code": 15,
  "transaction_id": <id>,
  "unit_id": <id>,
  "start_address": <addr>,
  "quantity": <qty>,
  "coils": [
    {
      "address": <addr>,
      "value": true,
      ...
    }
  ]
}
```

If not recognized, return: {"action": "unknown", "function_code": <fc>, "raw": <input>}

UNDER NO CIRCUMSTANCES SHOULD YOU INCLUDE ANY TEXT OUTSIDE THE JSON .

Prompt del LLM Generador

You are a Critical Low-Level Modbus Byte Encoder.
Your ONLY goal is to convert input data into a precise Hexadecimal String (PDU) without padding errors.

```
### INPUT DATA:
- 'function_code': Integer
- 'quantity': Integer
- 'simulation_data': List of values (Ints/Bools) OR 'simulation_data_hex' (List of hex strings).

### OUTPUT FORMAT:
JSON Object: '{"pdu_hex": "..."}'
### CRITICAL PROTOCOL RULES (DO NOT HALLUCINATE)
#### TYPE A: REGISTERS (FC 03, 04) -> "WIDE DATA"
* **Unit Size:** 2 Bytes (16 bits) per register.
* **Hex Width:** Must be exactly 4 characters per value.
* **Byte Count:** 'Quantity * 2'. Example: Qty=1, Val=255 -> '030200FF'.
#### TYPE B: COILS (FC 01, 02) -> "NARROW DATA"
* **Unit Size:** 1 Bit packed into Bytes.
* **Hex Width:** Must be exactly 2 characters per group of 8 coils.
* **Byte Count:** 'ceil(Quantity / 8)'. Do NOT output 4 characters for a single byte!

### VISUAL COMPARISON (MEMORIZE THIS)
| Operation | Qty | Value | WRONG | CORRECT |
| Read Coil | 1 | True | 01010001 | 010101 |
| Read Coil | 1 | False | 01010000 | 010100 |
| Read Reg | 1 | 255 | 0302FF | 030200FF |

### ALGORITHM TO FOLLOW:
1. Identify Function Code:
  - If 01 or 02: ACTIVATE "COIL MODE". Output strictly 2 hex chars per data byte.
  - If 03 or 04: ACTIVATE "REGISTER MODE". Output strictly 4 hex chars per data word.
  - If 05, 06, 15, 16: Echo/Ack per standard rules.
2. Generate PDU:
  - FC 01: If Qty <= 8: ByteCount='01'. Data='01' (True) or '00' (False). Result: '010101' or '010100'.
  - FC 03: If Qty = 1: ByteCount='02'. Data='XXXX'. Result: '0302XXXX'.

Input: {input_json}
RETURN ONLY JSON.
```

REFERENCIAS

- [1] K. Stouffer, V. Pillitteri, S. Lightman, M. Abrams, and A. Hahn, "Guide to industrial control systems (ics) security," National Institute of Standards and Technology, Tech. Rep. NIST SP 800-82 Rev. 2, 2015.
- [2] Departamento de Seguridad Nacional, "Estrategia de Seguridad Nacional 2021," Presidencia del Gobierno, Gobierno de España, Informe, 2021. [Online]. Available: https://www.dsn.gob.es/sites/default/files/documents/ESN2021%20Accesible_1.pdf
- [3] Ministerio del Interior, "Informe sobre la Cibercriminalidad en España 2022," Gobierno de España, Informe, 2023. [Online]. Available: <https://www.interior.gob.es/opencms/export/sites/default/galleries/galeria-de-prensa/documentos-y-multimedia/balances-e-informes/2022/Informe-Cibercriminalidad-2022.pdf>
- [4] C. Vasilatos, D. J. Mahboobeh, H. Lamri, M. Alam, and M. Maniatakos, "LLMPot: Dynamically Configured LLM-based Honeypot for Industrial Protocol and Physical Process Emulation," New York University Abu Dhabi, Center for Cyber Security, Research Paper, 2025. [Online]. Available: <https://arxiv.org/abs/2405.05999>
- [5] A. Cockburn, "Hexagonal architecture," alistair.cockburn.us, Article, 2005. [Online]. Available: <https://alistair.cockburn.us/hexagonal-architecture/>
- [6] SQLite Project, "SQLite Documentation," SQLite Project, Technical Documentation, 2026. [Online]. Available: <https://sqlite.org/docs.html>
- [7] OpenSearch Project, "OpenSearch Documentation," OpenSearch Project, Technical Documentation, 2026. [Online]. Available: <https://docs.opensearch.org/latest/about/>
- [8] I. Nai Fovino, A. Carcano, M. Masera, and A. Trombetta, "Design and Implementation of a Secure Modbus Protocol," Joint Research Centre (JRC), European Commission, Tech. Rep., 2009. [Online]. Available: <https://dl.ifip.org/db/conf/ifip11-10/cip2009/FovinoCMT09.pdf>
- [9] OpenAI, "GPT-4o mini: Model Documentation," OpenAI, Technical Documentation, 2024. [Online]. Available: <https://platform.openai.com/docs/models/gpt-4o-mini>
- [10] Nmap Project, "Nmap Reference Guide," Nmap Project, Technical Documentation, 2026. [Online]. Available: <https://nmap.org/book/man.html>
- [11] Wireshark Foundation, "Wireshark Official Documentation," Wireshark Foundation, Technical Documentation, 2026, accessed: 2026-01-13. [Online]. Available: <https://www.wireshark.org/docs/>
- [12] PyModbus Project, "PyModbus: A Python Modbus Stack Documentation," PyModbus Project, Technical Documentation, 2025. [Online]. Available: <https://pymodbus.readthedocs.io/en/latest/>

Sesión de pósters 3

Diseño conceptual de un marco de seguridad poscuántica para sistemas ciberfísicos

David Sobrín-Hidalgo
Universidad de León
Campus de Vegazana 24007 León
dsobh@unileon.es

Alexia Casado-González
Universidad de León
Campus de Vegazana 24007 León
acasg@unileon.es

Ángel Manuel Guerrero-Higueras
Universidad de León
Campus de Vegazana 24007 León
am.guerrero@unileon.es

Vicente Matellán-Olivera
Universidad de León
Campus de Vegazana 24007 León
vicente.matellan@unileon.es

Resumen—La tecnología cuántica plantea nuevos riesgos de seguridad en un futuro cercano debido a que los recursos de computación disponibles gracias a los ordenadores cuánticos provocarán que los mecanismos de criptografía modernos se vuelvan vulnerables. Esta situación es una importante amenaza, especialmente para aquellos sectores que utilizan sistemas ciberfísicos cuya vida útil es larga como, por ejemplo, los vehículos o los robots. La adaptación de estos sistemas a la era poscuántica representa una necesidad, pero también un desafío debido a la naturaleza de estos sistemas y a la limitación que presentan en lo referente a recursos internos. Este artículo propone un diseño de arquitectura preliminar para securizar la telemetría de un sistema ciberfísico frente a posibles atacantes con capacidades cuánticas. Para ello se ha elaborado un modelo de amenaza en el que se analizan las dimensiones de seguridad, las amenazas presentes en dichas dimensiones y las posibles mitigaciones poscuánticas. Por último se presenta una primera aproximación de la arquitectura, la cual incluye métodos de criptografía poscuántica, firma digital e intercambio cuántico de claves.

Index Terms—Trazabilidad, criptografía, poscuántica, ciberseguridad.

Tipo de contribución: Investigación en desarrollo

I. INTRODUCCIÓN

La inminente llegada de ordenadores cuánticos representa una amenaza para los algoritmos criptográficos actuales. La seguridad actual se basa en criptografía de clave pública, no obstante estos métodos se volverán vulnerables durante la era poscuántica. Los algoritmos Shor [1] o Grover [2] debilitarán los sistemas asimétricos (RSA, ECC) y simétricos (AES).

La amenaza que suponen estos algoritmos cuánticos adquiere una notable importancia en sistemas cuyo ciclo de vida útil es largo, como los vehículos y los sistemas robóticos, ya que no estarán protegidos en la era poscuántica [3]. Una de las amenazas principales que hacen evidente la necesidad de la integración de cifrado poscuántico (*"Post-Quantum Cryptography"* o PQC) es la estrategia conocida como *"Cosechar ahora, descifrar después"* (*Harvest Now, Decrypt Later (HNDL)*) [4]. Dicho ataque consiste en recopilar en la actualidad grandes cantidades de datos sensibles y cifrados, para descifrarlos cuando los recursos cuánticos sean más accesibles.

El presente trabajo se centra en la integración de una capa de seguridad cuántica en las comunicaciones de sistemas

ciberfísicos (*"Cyber-physical System"* o CPS). Aunque existe una gran diversidad de CPSs, este trabajo se ha planteado fundamentalmente en torno a vehículos, robots y drones. El **objetivo** que guía el presente artículo consiste, por tanto, en desarrollar una propuesta de solución software que permita garantizar la seguridad contra ataques poscuánticos, mientras asegura capacidades de auditabilidad de la telemetría de un sistema ciberfísico.

El presente artículo se estructura de la siguiente forma. En la **Sección II** se realiza un resumen del estado del arte sobre los estándares y algoritmos poscuánticos actuales, así como la situación en la que se encuentran los sistemas automotrices y robóticos en materia de seguridad poscuántica. La **Sección III** presenta el modelo de amenaza que se ha utilizado como base para la propuesta planteada. El diseño, requisitos y arquitectura de seguridad planteados se desarrollan en la **Sección IV**. Por último, en la **Sección VI** se recogen las conclusiones del trabajo y se plantean las futuras líneas de investigación.

II. ANÁLISIS DEL ESTADO DE LA CUESTIÓN

En la presente sección se proporciona un breve resumen del estado de la cuestión, desde los estándares actuales hasta la integración de mecanismos de seguridad poscuántica en vehículos, robots y drones.

El *"National Institute of Standards and Technology"* (NIST) lidera el proyecto de estandarización de algoritmos de criptografía poscuántica con el objetivo de seleccionar algoritmos resistentes a ataques cuánticos. De forma paralela al proyecto de estandarización del NIST, ETSI ha establecido el *"Industry Specification Group on Quantum-Safe Cryptography"* o ISG QSC. ETSI proporciona directrices, modelos de amenaza y perfiles de implementación de algoritmos poscuánticos en las infraestructuras existentes.

La modernización de la industria automotriz ha conducido a asegurar la integridad de la comunicaciones y la autenticación. En [3] se analiza el estado del arte y se destaca la importancia de la securización de las comunicaciones contra ataques poscuánticos.

Respecto a los sistemas robóticos, en [5], los autores realizan un estudio sobre esquemas de integración de PQC en *"Robot Operating System"* (ROS), el estándar de facto

en lo que respecta a *middleware* para la construcción de aplicaciones robóticas.

III. MODELO DE AMENAZA

La propuesta presentada en este artículo busca mejorar la ciberseguridad de los sistemas ciberfísicos. Para ello resulta de interés realizar un análisis previo de las propiedades de seguridad de estos sistemas y cómo se verían afectadas en un contexto poscuántico. Para ello se ha elaborado un posible modelo de amenaza y se han estudiado las dimensiones de la ciberseguridad en base a dicho modelo.

III-A. Modelo de amenaza

Este trabajo considera un modelo de adversario realista y con capacidades avanzadas, en especial con capacidades de computación cuántica, y acceso físico y lógico a los sistemas. El modelo de amenaza planteado está alineado con un escenario poscuántico y orientado a las particularidades de los sistemas ciberfísicos, en concreto robots móviles y vehículos.

A continuación se resumen las capacidades del adversario:

1. **Capacidades de criptografía cuántica:** La principal motivación de este trabajo es la securización de CPSs frente a ataques cuánticos. Por ello se asume que el adversario tiene acceso a computadores cuánticos capaces de romper de forma eficiente los esquemas de criptografía clásicos como RSA. El adversario puede ejecutar estrategias de HNDL, para ello se asume que tiene acceso a comunicaciones encriptadas grabadas en un escenario previo a la computación cuántica.
2. **Acceso a la red de comunicaciones:** Una parte significativa de las amenazas que afectan a robots y vehículos tienen como requisito tener acceso a la red en la que trabaja el sistema, especialmente en entornos inalámbricos como **Wi-Fi, 5G o V2X**. En el presente modelo de amenaza se considera un escenario en el cual el atacante dispone de acceso a nivel de red, motivado por el hecho de que los mecanismos clásicos de autenticación y establecimiento de claves resultan vulnerables ante ataques cuánticos.
3. **Ataques tradicionales a CPS:** Se considera que el atacante tiene la capacidad de realizar ataques tradicionales contra los sistemas. En [6] se documenta el proceso de auditoria a diferentes sistemas autónomos, además de establecer una taxonomía de amenaza. Dicho informe sirve como base para establecer algunas de las acciones que puede llevar a cabo el adversario. Estas acciones se listan a continuación.
 - Escucha pasiva del canal de comunicación.
 - Denegación de servicio.
 - Inyección de comandos maliciosos y alteración del comportamiento del sistema.
 - Manipulación de los datos de sensores.
4. **Manipulación física:** La autonomía y exposición del hardware de algunos sistemas ciberfísicos provoca que sean vulnerables ante manipulación física la cual incluye: daños en sensores o actuadores, robo de hardware o inyección de malware a través de interfaces físicas.

III-B. Dimensiones de la ciberseguridad: impacto y mitigación

A partir del modelo de amenaza propuesto, se va a estudiar el impacto del mismo en cada una de las dimensiones de la ciberseguridad, así como el nivel de mitigación alcanzado a través de la integración de un sistema resistente ante ataques cuánticos.

Para el análisis planteado se parte de las tres dimensiones tradicionales de la seguridad de la información recogidas en la triada CIA [7]: Confidencialidad, Integridad y Disponibilidad. No obstante, con el objetivo de abarcar de forma más completa las áreas de impacto asociadas a la amenaza cuántica en CPS's, se han considerado modelos ampliados de seguridad de la información [8], [9] y se han extraído otros seis atributos adicionales: Autenticidad, trazabilidad o no-repudio, auditabilidad, resiliencia, confiabilidad y frescura o no-reutilización. La **Figura 1** representa de forma gráfica las dimensiones planteadas.



Figura 1. Dimensiones de la seguridad para el modelo planteado.

IV. DISEÑO DEL SISTEMA

En esta sección se detalla la propuesta planteada para la securización de un sistema ciberfísico. El planteamiento se basa en **encriptar la telemetría** y en **asegurar la trazabilidad y el no repudio de los datos**.

IV-A. Encriptación de la telemetría

El sistema planteado debe asegurar la integridad de la información generada por el CPS. La securización de un canal de información se basa principalmente en el cifrado de los datos y en la autenticación de los actores de la comunicación.

Los datos generados por el CPS pueden dividirse en los dos siguientes ámbitos:

- **Telemetría interna:** Comunicación entre los diferentes subsistemas del CPS.
 - **Ejemplo para un robot (ROS 2):** Comunicación entre nodos dentro del robot.
 - **Ejemplo para un vehículo:** Coordinación de los sistemas electrónicos del vehículo (sensores, actuadores y unidades de control).
 - **Posibles protocolos implicados:** Implementaciones DDS para ROS 2, CAN.
- **Telemetría externa:** Comunicación entre el CPS y un sistema externo.
 - **Ejemplo para un robot (ROS 2):** Comunicación entre el robot y la aplicación Android a la que

se conecta para realizar tareas de monitorización y teleoperación.

- **Ejemplo para un vehículo:** Conexión con el fabricante para actualizaciones, teleoperación o envío de datos de diagnóstico.
- **Posibles protocolos implicados:** Wi-Fi, 4G/5G, Ethernet, Bluetooth, V2X

La propuesta se centra principalmente en securizar la telemetría externa. La necesidad de dotar a los CPS de capacidades de trazabilidad y explicabilidad robustas hace fundamental la creación de canales de comunicación seguros para analizar los datos en tiempo real y enviarlos desde el CPS hasta un almacén de evidencias.

Para lograr un canal seguro frente a adversarios con capacidades cuánticas se ha planteado un diseño híbrido que combina PQC con QKD. Partiendo de esta base, la comunicación comienza con la autenticación mutua entre el CPS y el nodo externo mediante firmas digitales poscuánticas. Posteriormente, se emplea QKD para generar claves simétricas compartidas, las cuales se utilizan para cifrar la telemetría mediante algoritmos simétricos eficientes.

IV-B. Asegurar trazabilidad y no repudio

Para asegurar que el CPS cuente con capacidades de trazabilidad y explicabilidad es necesario incorporar mecanismos que permitan reconstruir a posteriori la secuencia de eventos, el proceso de toma de decisiones y las comunicaciones realizadas durante la operación. Resulta fundamental, además, garantizar la integridad y el no repudio de los registros.

Para lograr este objetivo, se propone combinar un almacén de evidencias distribuido en la nube basado en tecnología blockchain y un almacén de registros local tipo "caja negra", de forma que sea posible realizar una validación cruzada entre ambos almacenamientos. Para asegurar este sistema de almacenamiento se propone el uso de PQC junto con firmas digitales poscuánticas.

IV-B1. Almacenamiento forense de evidencias.: De forma complementaria al almacén local, el sistema permite el registro seguro de evidencias en la nube, dónde solamente entidades autorizadas pueden realizar registros o validar datos.

Al contrario que en el módulo de caja negra, los datos críticos se resumen mediante una función hash y se registran como transacción en la blockchain. De esta forma se asegura la trazabilidad, la inmutabilidad y el no repudio. No obstante para asegurar este proceso desde una perspectiva poscuántica es necesario que el sistema utilice funciones hash seguras ante adversarios con capacidades cuánticas, así como mecanismos de firma digital cuánticos.

Combinando ambos almacenamientos se consigue que, en caso de fallo o accidente, se pueda extraer la información contenida en la caja negra y contrastarla con las evidencias registradas en la blockchain.

IV-C. Arquitectura

En esta sección se presenta la arquitectura de seguridad y trazabilidad diseñada para implementar un sistema de trazabilidad con almacenamiento seguro y envío de telemetría protegido contra ataques cuánticos.

El objetivo de esta propuesta es que la arquitectura planteada sea generalizable a distintos tipos de CPS, principalmente

robots, vehículos y drones. Por lo tanto uno de los requisitos principales es que sea compatible con el formato de datos de ROS 2, así como con los datos que componen la telemetría de un vehículo.

Puesto que la securización a nivel cuántico de la telemetría externa del CPS se ha planteado como la adición de una nueva capa en las comunicaciones, el formato de los datos no tiene un impacto directo en la seguridad, aunque podría considerarse la creación de pequeños módulos de procesamiento y curado de datos para adaptar nuevos sistemas a la arquitectura planteada.

El diseño de la arquitectura del sistema a alto nivel se recoge en la **Figura 2**. En ella se pueden identificar tres componentes principales: Almacén de datos local tipo BB, módulo de preprocesamiento de los datos y almacén externo de evidencias

El funcionamiento básico del sistema de trazabilidad puede dividirse en dos partes bien diferenciadas: la **securización de la telemetría** y la **recuperación de los datos**.

Respecto a la securización poscuántica de la telemetría, el sistema autónomo, en este caso un robot, primero genera datos mientras realiza su comportamiento. Estos datos se registran en el almacenamiento local y se envían cifrados a través de la red. En el destino, los datos se descifran y pueden ser utilizados para realizar labores de monitorización o almacenaje. Este proceso está representado en rojo en la **Figura 2**.




Figura 2. Diseño a alto nivel del sistema de trazabilidad.

Una vez descryptados los datos en el destino, el módulo de preprocesado extrae una serie de evidencias a partir de los mismos y registra dichas evidencias en el almacenamiento externo. Para la recuperación de los datos, el usuario puede realizar peticiones al almacenamiento local y, una vez recibido el dato deseado, comprobar su integridad y validez utilizando las evidencias almacenadas en la nube (también mediante un sistema de petición-respuesta).

En cuanto al intercambio de datos cifrados, se plantea integrar módulos de QKD destinados al establecimiento seguro de claves, así como de PQC, orientados al cifrado y a las firmas digitales resistentes a ataques cuánticos. De esta forma se garantiza la confidencialidad, la integridad y el no repudio de los datos durante su envío. En la **Figura 3** se aprecia, en mayor detalle, el esquema de distribución de claves cuántico propuesto.




Figura 3. Flujo de datos protegido con mecanismos poscuánticos.

El canal de comunicación utilizado para la transmisión de los datos está protegido a nivel cuántico mediante la integración de mecanismos de cifrado, firma digital e intercambio de claves. A continuación se detalla la estructura de dicho sistema.

- **KME (Key Management Entity) Central:** Se corresponde con el gestor de claves. Define políticas de seguridad y se encarga de gestionar la rotación, revocación y distribución de claves PQC y QKD.
- **SAE (Security Application Engine):** Módulo de seguridad de aplicación que se encarga de gestionar los mecanismos criptográficos en cada extremo de la comunicación. La propuesta plantea el uso de dos SAEs distintos:
 - **SAE Origen:** Envía la telemetría. Para ello, primero solicita la clave de sesión al KME de borde correspondiente. Cifra y firma los datos utilizando la clave solicitada.
 - **SAE Destino:** Recibe la telemetría cifrada y firmada. Solicita la misma clave a su KME de borde. Una vez obtenida la clave, verifica la firma y descifra los datos.
- **KME de borde:** Se utiliza uno por cada extremo y actúan como intermediarios de las claves. Recibe las solicitudes del SAE y se comunica con el KME Central para obtener claves, aplicar políticas de seguridad y gestionar la rotación.

V. DISCUSIÓN

La implementación práctica de la arquitectura propuesta plantea desafíos relevantes, especialmente por las limitaciones de recursos de los CPS, que afectan al rendimiento y a su viabilidad de despliegue. El uso de blockchain y QKD aporta ventajas en trazabilidad y seguridad, pero incrementa el coste computacional y de infraestructura, lo que puede resultar excesivo para telemetría en tiempo real. En particular, QKD presenta actualmente limitaciones de coste y complejidad, por lo que su inclusión en esta propuesta debe entenderse como una línea exploratoria, cuya viabilidad dependerá del contexto de despliegue y de la evolución tecnológica en este ámbito.

VI. CONCLUSIONES

Este artículo presenta una investigación en desarrollo cuyo objetivo es el desarrollo de una arquitectura para la securización de la telemetría de sistemas ciberfísicos. A través de la integración de mecanismos cuánticos, concretamente QKD y criptografía poscuántica, se pretende crear un canal de comunicación resiliente ante atacantes con capacidades cuánticas. Asimismo, la incorporación de esquemas de firma digital y de un sistema de registro de evidencias, combinando almacenamiento local y almacenamiento en la nube soportado por blockchain, proporciona al CPS capacidades de trazabilidad y auditabilidad verificables.

La integración de mecanismos poscuánticos en CPS como vehículos y robots enfrenta varios desafíos, principalmente relacionados con el rendimiento y la escasez de recursos que caracterizan a dichos sistemas. Si bien el presente artículo no contempla dichos problemas, resulta fundamental considerarlos y encontrar alternativas que permitan integrar algoritmos de criptografía poscuántica en este tipo de sistemas.

En trabajos futuros se pretende realizar una prueba de concepto para implementar la arquitectura propuesta y desplegarla sobre diferentes CPS reales como un robot manipulador móvil, un vehículo moderno y un dron. Además se planea realizar una revisión de literatura sobre ataques cuánticos contra CPS y mecanismos de mitigación securización.

AGRADECIMIENTOS

La presente investigación ha sido financiada por la ayuda Explicit PID2024-162298OB-I00 financiada por MICIU/AEI/10.13039/501100011033 y según proceda, por “FEDER Una manera de hacer Europa”, por “FEDER/UE”, por la “Unión Europea”.

Los autores agradecen el apoyo de SCAYLE a esta investigación en el marco del proyecto Cindirella-QKD.

REFERENCIAS

- [1] P. W. Shor, “Polynomial-time algorithms for prime factorization and discrete logarithms on a quantum computer,” *SIAM review*, vol. 41, no. 2, pp. 303–332, 1999.
- [2] L. K. Grover, “A fast quantum mechanical algorithm for database search,” in *Proceedings of the twenty-eighth annual ACM symposium on Theory of computing*, 1996, pp. 212–219.
- [3] N. Lohmiller, S. Kaniewski, M. Menth, and T. Heer, “A survey of post-quantum cryptography migration in vehicles,” *IEEE Access*, 2025.
- [4] G. Noone, “Are harvest now, decrypt later cyberattacks actually happening?” *Tech Monitor*, 2023.
- [5] R. Varma, C. Melville, C. Pinello, and T. Sahai, “Post quantum secure command and control of mobile agents inserting quantum-resistant encryption schemes in the secure robot operating system,” *International Journal of Semantic Computing*, vol. 15, no. 03, pp. 359–379, 2021.
- [6] A. Campazas-Vega, C. Álvarez Aparicio, D. Sobrín-Hidalgo, L. Inyesto-Alonso, F. J. Rodríguez-Lera, V. Matellán-Olivera, and Ángel Manuel Guerrero-Higueras, “Procedimiento de auditoría de ciberseguridad para sistemas autónomos: metodología, amenazas y mitigaciones,” 2025. [Online]. Available: <https://arxiv.org/abs/2511.05185>
- [7] C. K. Yee and M. F. Zolkipli, “Review on confidentiality, integrity and availability in information security,” *Journal of ICT in Education*, vol. 8, no. 2, pp. 34–42, 2021.
- [8] T. Lu, X. Guo, L. Zhao, Y. Li, P. Lin, and B. Fang, “Security model for sensitive information systems and its applications in sensor networks,” *International Journal of Security and Its Applications*, vol. 9, no. 5, pp. 1–18, 2015.
- [9] G. Pender-Bey, “The parkerian hexad,” *Information Security Program at Lewis University*, 2019.

Riesgos Informacionales y Geopolíticos de la Cumbre Iberoamericana de Madrid 2026

Albert Borràs Rius
Kartex Risk / Universidad Carlos III
de Madrid / ESFAS – CESEDEN-
Universidad Nebrija
Madrid, España |
albert@kartexrisk.com
Albert Borràs Rius

Resumen- Este artículo analiza los riesgos informacionales y geopolíticos de la Cumbre Iberoamericana de Madrid 2026 (4-5 noviembre) a partir del ecosistema discursivo digital generado en torno a la XXIX Cumbre de Cuenca (Ecuador, 14-15 noviembre 2024). El ciberespacio se comporta como extensión del territorio donde estrategias de poder cristalizan sobre sus tres capas: física, lógica e informacional. Mediante análisis lingüístico-discursivo de un corpus de 3.761 tweets (48.648 RTs, 2.009 cuentas únicas), se identifican seis marcos narrativos dominantes, un ecosistema sustancialmente orgánico y la ausencia de campañas coordinadas de influencia durante la Cumbre de Cuenca. Se detecta, sin embargo, que el argumento comparativo BRICS-Iberoamérica articulado por @AnibalGarzon (1.518 RTs) constituye el vector narrativo anti-atlantista y prorruso de mayor potencial de reactivación en Madrid 2026. La hipótesis central sostiene que la baja relevancia del evento iberoamericano no equivale a ausencia de vulnerabilidad, sino a una potencial ventana de activación de narrativas de influencia en el espacio hispanohablante.

Index Terms- Desinformación; Ciberespacio; Geopolítica; Operaciones de influencia; Cumbre Iberoamericana; Rusia;

Ecosistemas digitales; Análisis discursivo; Seguridad informacional.

Tipo de contribución: Investigación original. Proyecto DECIGODI, INCIBE / fondos Next Generation EU.

INTRODUCCIÓN

La visión inicial de Internet como espacio de intercambio y democratización de ideas está perdiendo peso mientras el ciberespacio se comporta como extensión del territorio, donde estrategias de poder cristalizan sobre sus capas física, lógica e informacional. Los cambios en la política estadounidense con la segunda presidencia de Trump aceleran la reconfiguración de la globalización y redistribuyen poder en un sistema multipolar con señales de erosión del orden liberal [1]. En este contexto de gobernanzas cuestionadas y sociedades polarizadas, es previsible un aumento de tensiones. El espacio iberoamericano no es ajeno a estas dinámicas: América Latina atraviesa desplazamientos migratorios, crimen transnacional y amenazas informacionales en un marco de polarización creciente. La esfera informacional se ha convertido en escenario privilegiado para desinformación, manipulación narrativa y movilización disruptiva en la lógica de conflicto híbrido donde la distinción entre guerra y paz se difumina en las «zonas grises» [2].




Fig.1

La lengua española, con 520 millones de hablantes nativos y estatuto oficial en 21 Estados, configura un espacio informacional de gran alcance particularmente atractivo para campañas de injerencia con efectos sistémicos transfronterizos [3][4]. La fragmentación del discurso en distintas plataformas y las debilidades informacionales de las redes configuran el ciberespacio hispanohablante como entorno vulnerable y permeable.

La lengua se configura no solo como aliada de la representación geopolítica de Iberoamérica, sino también como activo estratégico en la defensa de la soberanía digital y cognitiva frente a arquitecturas tecnológicas y campañas de desinformación que priman la polarización y la erosión de los sistemas democráticos.

La XXIX Cumbre Iberoamericana de Jefes de Estado se celebró en Cuenca (Ecuador) los días 14-15 de noviembre de 2024. Se saldó con una declaración final parcial —fruto del choque entre Cuba y Argentina en plenaria— y con el récord histórico de ausencias: de 22 países convocados, solo asistieron el presidente Daniel Noboa (Ecuador, anfitrión), el rey Felipe VI, el presidente de Portugal Rebelo de Sousa y el jefe de gobierno de Andorra. Ningún presidente latinoamericano fuera del anfitrión asistió.

Este evento constituye un laboratorio analítico privilegiado para comprender los ecosistemas discursivos digitales del espacio iberoamericano. El traspaso de la Secretaría Pro Tempore a España para la Cumbre de Madrid —4 y 5 de noviembre de 2026— convierte a España en garante de la continuidad del foro.

La hipótesis central sostiene que, aunque la Cumbre 2024 no generó un ecosistema disruptivo visible ni campañas coordinadas detectables, su baja relevancia mediática evidencia una vulnerabilidad estructural: la potencial activación artificial de narrativas de influencia en futuros eventos de mayor simbolismo geopolítico como Madrid 2026. Los objetivos son: (1) analizar el ecosistema discursivo en X/Twitter durante la Cumbre 2024 identificando marcos narrativos y patrones de coordinación; (2) detectar indicadores de artificialidad discursiva; y (3) evaluar los riesgos geopolíticos e informacionales para Madrid 2026.

II. MARCO TEÓRICO-METODOLÓGICO

A. Ciberespacio, lengua y transnacionalidad

Internet se percibió inicialmente como ámbito de libertad más que de poder. El auge de las redes sociales entre 2010 y 2015 transformó los flujos informativos, horizontalizándolos y transnacionalizándolos, facilitando la Primavera Árabe, el movimiento de los indignados en España y las protestas cubanas de 2021 [5]. No obstante, las campañas de desinformación y los ciberataques se han convertido en instrumentos estratégicos de actores estatales y no estatales. El comportamiento informacional, aunque aparentemente sin fronteras, genera patrones espaciales vinculados a conexiones lingüísticas, políticas e ideológicas, convirtiendo el español en un espacio muy vulnerable a campañas de injerencia con repercusión transnacional. El ciberespacio hispanohablante atraviesa un momento de pugna por el interés que América Latina suscita en potencias que impulsan la redefinición de alianzas a través de los BRICS.

B. Dinámicas informacionales en el espacio iberoamericano

La desinformación no se limita a la difusión de bulos: implica la capacidad de articular estrategias en la capa informacional mediante bots, trolls, proxies y redes organizadas en cámaras de eco con el objetivo de socavar equilibrios políticos, generando dinámicas de radicalización y

polarización acompañadas de estrategias híbridas paralelas. México ofrece una radiografía paradigmática: granjas de cuentas coordinadas para difamar candidatos desde 2018 [6], distribución televisiva de RT en español y campaña con códigos QR en vía pública conectando directamente con la emisión sin trazabilidad contractual [7]. En Brasil, WhatsApp fue vector de microsegmentación de baja trazabilidad [8]; en España, 2.882 cuentas con origen en Venezuela amplificaron contenidos a favor de Vox entre 2017 y 2019 [8].

Las redes bolivarianas actuaron como altavoces en el procés catalán, apoyando al independentismo mientras cuestionaban la legitimidad del Estado español [9]. Rusia ha perfeccionado un modelo modular que combina medios paraestatales (RT/Sputnik), marcas blancas y clonado de dominios (ecosistema Doppelgänger), articulado con canales de extrema izquierda en español que legitiman narrativas del Kremlin como puentes hacia audiencias ibéricas y latinoamericanas [11][12]. La detención en Lituania de dos ciudadanos vascos reclutados vía Telegram y el canje de Pablo González como espía en el mayor intercambio de prisioneros desde la Guerra Fría ilustran que la radicalización informacional y la acción física son capas complementarias del mismo sistema [13].

C. Metodología

El corpus comprende 3.761 tweets en español capturados mediante Visibrain entre el 6 y el 20 de noviembre de 2024. La metodología combina análisis lexicométrico de frecuencia y co-ocurrencias, identificación de marcos narrativos [10], distribución temporal y evaluación de artificialidad mediante ratios RT/seguidores y análisis de duplicados.

III. ANÁLISIS INFORMACIONAL: CUMBRE IBEROAMERICANA 2024

A. Corpus analizado

El léxico dominante revela polarización semántica estructural: 'fracaso' (161), 'ausencia' (140) y 'bloqueo' (107) coexisten con el léxico oficial ('cooperación': 133, 'inclusión': 94). Los bigramas más relevantes son 'jefes estado' (865) —articulando el nivel de representación requerido frente al ausente— y 'maduro enterrar' (58), referido a la declaración de Maduro «fueron a enterrar la cumbre en Ecuador». El pico de actividad se registra el 15 de noviembre (985 tweets), coincidiendo con el choque Cuba-Argentina en plenaria; el segundo pico es el 14 de noviembre (871 tweets), día de inauguración y confirmación de ausencias.

B. Marcos narrativos e interpretación del corpus

F1 – Fracaso/ausencias récord (~35%): Frame dominante y transversal a posicionamientos ideológicos muy distintos, que encuadra la cumbre como el mayor fracaso en los 32 años del foro. La izquierda ecuatoriana atribuye las ausencias al aislamiento de Noboa por el allanamiento de la embajada mexicana (caso Glas, abril 2024, que rompió relaciones con México); la derecha señala la crisis energética (apagones de 14 horas) y la inseguridad; los medios internacionales apuntan a la erosión estructural del foro. @MoniPalaciosZ (72K seg., 1.071 RTs): «Ecuador rompe el récord de líderes ausentes [...] ¿Quién querría visitar el Nuevo Ecuador de Noboa?»

F2 – Choque Cuba-Argentina/sin declaración (~15%): La delegación argentina exige que la declaración no guarde silencio sobre Cuba, Venezuela y Nicaragua; la cubana responde que Milei 'maltrata a jubilados'. El intercambio bloquea el consenso. @UHN_Plus (1,1M seg., 2.404 RTs —el tweet más viral del corpus—): «Fuerte choque entre las delegaciones de Cuba y Argentina. El cruce de descalificativos bloqueó la resolución final.» Reproduce en el foro

iberoamericano la fractura hemisférica más profunda sobre legitimidad democrática.

F3 – Noboa: aislamiento y crisis doméstica (~20%): Combina el allanamiento de la embajada mexicana con la crisis energética y el aislamiento internacional post-caso Glas. @Danielsalcán_ (71K seg., 661 RTs): «No asistirá ni un solo presidente de Sudamérica. Noboa es el nuevo Maduro de la región.» La Revolución Ciudadana instrumentaliza el fracaso como munición de campaña anticipada hacia las elecciones de 2025, convirtiendo el evento multilateral en campo de batalla electoral interno.

F4 – Cuba/bloqueo/castrismo (~8%): El único frame coordinado de forma explícita. @CubaMINREX (315K seg., 2.369 RTs acumulados) activa #TumbaElBloqueo en sincronía con las intervenciones cubanas en plenaria. La instrumentalización del 25 aniversario de la IX Cumbre de La Habana (noviembre 1999) mediante fotografías y discursos de Fidel Castro (@FSoldadodeIdeas, 777 RTs) funciona como legitimación histórica. Es diplomacia digital de Estado — explícita y legítima —, no una operación encubierta.

F5 – Declive iberoamericano/comparación BRICS (~5%): Geopolíticamente el más relevante pese a ser el más pequeño en volumen. @AnibalGarzon (93K seg., 1.518 RTs —2.º tweet más viral—): «Sánchez decía que la guerra de Ucrania aislaría a Rusia. Rusia celebró la Cumbre BRICS con más de 20 jefes de estado, mientras en la Cumbre Iberoamericana fundada por España solo participaron 3. Parece España más aislada que Rusia.» Opera sobre datos reales para construir un marco interpretativo prorruso con autoridad académico-divulgativa que desactiva los mecanismos de alerta epistémica.

F6 – Narrativa oficial/SEGIB (~10%): El menos eficaz. La afirmación de la canciller ecuatoriana de que la cumbre fue un 'éxito' genera amplia ironía. @CasaReal (1,19M seg., 1.887 RTs) aporta el único contrapeso institucional positivo español, centrado en el protocolo del traspaso de la Secretaría Pro Tempore a España para 2026.

El corpus estructura cuatro ejes de polarización discursiva. El Eje 1 (fracaso de Noboa/fracaso del multilateralismo) enfrenta al polo que atribuye las ausencias al aislamiento de Ecuador frente al polo analítico que apunta a la erosión estructural del foro. El Eje 2 (democracias vs. dictaduras: Argentina/Milei vs. Cuba/Venezuela) reproduce la fractura hemisférica sobre qué regímenes merecen legitimidad multilateral y si los foros deben exigir rendición de cuentas democrática o respetar la no injerencia. El Eje 3 (declive de España/vigencia del espacio iberoamericano) formula la pregunta más incómoda: ¿sigue siendo la Cumbre Iberoamericana un foro relevante en el tablero geopolítico del siglo XXI? El Eje 4 (Ecuador 2025/evaluación de Noboa) documenta la instrumentalización del fracaso como campo de batalla electoral anticipada.

C. Coordinación, amplificación y dinámica temporal

La evaluación global del corpus es de organicidad sustancial. La diversidad de posicionamientos, la presencia de medios verificados con audiencias masivas y la coherencia temporal con los eventos reales son indicadores convergentes de conversación genuina. No se detectan bots ni operaciones de información artificial. El nivel de coordinación artificial es bajo: únicamente 5 tweets con el mismo enlace de @ElDatoEcu y 3 tweets sobre ausencias con texto casi idéntico. Varias cuentas presentan ratios de amplificación desproporcionadas compatibles con grupos de Telegram o WhatsApp externos a la plataforma: @carlosbravoma (4.404 seg., 284 RTs, ratio 0,064), @ElenaDeQuito (9.706 seg., 591 RTs, ratio 0,061), @FSoldadodeIdeas (16.540 seg., 777 RTs, ratio 0,047). La única coordinación sistemática identificada es

la del aparato comunicacional cubano —transparente y estatal—.

La dinámica temporal del corpus identifica los detonantes de cada pico discursivo. El 11 de noviembre se produce la primera activación (145 tweets): @radio pichincha publica «Nadie quiere venir a la Cumbre». El 12 de noviembre aumenta hasta 330 tweets, impulsado por @MashiRafael («imagen del país destrozada», 628 RTs). El 13 de noviembre, @MoniPalaciosZ genera 1.071 RTs con el «papelón internacional» de Ecuador. El 14 de noviembre constituye el primer pico (871 tweets): inauguración, llegada de Felipe VI (@CasaReal, 499 RTs), @Danielsalcán_ («Noboa es el nuevo Maduro», 660 RTs), y confirmación de la ausencia de Paraguay —último presidente posible—. El 15 de noviembre es el pico máximo (985 tweets): @UHN_Plus acumula 2.404 RTs, @JorgeGestoso 1.474 RTs, @AlbertoRodNews 658 RTs y @CubaMINREX activa sus intervenciones de plenaria de forma sincronizada. El 16 de noviembre se publican los tweets geopolíticamente más relevantes: @AnibalGarzon (1.518 RTs, comparación BRICS-Iberoamérica), @GuillaumeLong (626 RTs: «Noboa centró la cumbre demasiado en él mismo») y @CasaReal con el traspaso de la Secretaría Pro Tempore. El período 17-20 registra el declive post-evento con análisis e instrumentalización electoral ecuatoriana.

IV. DERIVADAS ESTRATÉGICAS Y VECTORES DE ACTIVACIÓN

A. El argumento BRICS-Iberoamérica como vector narrativo persistente

El Frame 5 es cuantitativamente el más pequeño del corpus pero geopolíticamente el más relevante para Madrid 2026. @AnibalGarzon (93.125 seguidores), analista del libro BRICS: La transición hacia un orden mundial alternativo (Akal, 2023) [15] y colaborador habitual de RT en Español y Sputnik Mundo, articula el argumento más potente en términos de relaciones internacionales: mientras la Cumbre Iberoamericana fundada por España reunía a solo 3 representantes en Cuenca, la Cumbre de los BRICS atrajo a más de 20 jefes de Estado. La pregunta «¿Parece España más aislada que Rusia?» conecta el fracaso puntual con la tendencia histórica de reconfiguración del poder mundial y circula con 1.518 RTs, siendo el segundo tweet más viral del corpus.

El eje de polarización discursiva entre el «declive de España» y la «vigencia del espacio iberoamericano» plantea la pregunta más incómoda para España y la SEGIB: ¿sigue siendo la Cumbre Iberoamericana un foro relevante en el tablero geopolítico del siglo XXI? El traspaso a España para 2026 es simultáneamente una oportunidad (reconstruir el foro) y un riesgo (si la cumbre de 2026 también fracasa en términos de asistencia, la pérdida de relevancia podría ser definitiva). La movilización de la extrema izquierda en torno a los discursos de Anibal Garzón —sociólogo con presencia regular en RT y autor del libro BRICS— y sus conexiones con el ecosistema prorruso identificado en el proyecto DECIGODI evidencian una activación plausible ante un evento de mayor visibilidad como Madrid 2026.

B. Ecosistemas de amplificación y actores estructurales

El análisis de circulación multiplataforma revela actores con función estructural. @UHN_Plus actúa como nodo de amplificación hemisférica: acumula 2.404 RTs con un único tweet movilizándolo la opinión pública antichavista de la diáspora cubana y venezolana en Florida. @CubaMINREX coordina la publicación de vídeos de las intervenciones de la delegación cubana que circulan simultáneamente en Twitter y YouTube con el hashtag #TumbaElBloqueo activado de forma sincronizada —la narrativa más coherente y estratégicamente

articulada del corpus—. Los medios ecuatorianos (@EcuavisaInforma, 2,3M; @Primicias, 1,27M; @radio_pichincha, 210K) producen el contenido informativo primario que el resto de actores amplifica. El ecosistema Correa/Revolución Ciudadana opera con alta disciplina narrativa conectando el fracaso diplomático con la crisis doméstica ecuatoriana, convirtiendo el evento multilateral en campo de batalla de campaña anticipada. @CasaReal española aporta el único contrapeso de narrativa institucional positiva al corpus, evidenciando un déficit de estrategia comunicacional proactiva española que debe corregirse para Madrid 2026.

V. RIESGOS Y OPORTUNIDADES: MADRID 2026

A. El ciberespacio como campo de batalla híbrida

El análisis del ecosistema de Cuenca pone de manifiesto que la ausencia de activación coordinada no equivale a ausencia de riesgo estructural. Madrid 2026 constituye un escenario cualitativamente distinto: mayor visibilidad internacional, capital simbólica de la presidencia española y un contexto geopolítico marcado por la guerra en Ucrania, la reconfiguración multipolar y el debilitamiento de los consensos occidentales. Conviene enmarcar los riesgos en la lógica de la guerra híbrida: combinación deliberada de acciones militares, de inteligencia, económicas e informativas para erosionar la cohesión de los adversarios sin cruzar el umbral del conflicto convencional. En este modelo, el ciberespacio informativo no es un dominio separado sino el sustrato cognitivo que prepara, acompaña y legitima las acciones en el terreno físico.

Los casos documentados en el mismo período confirman que radicalización informativa y acción física son capas complementarias: la detención en Lituania de dos ciudadanos vascos reclutados vía Telegram para un atentado contra una empresa proveedora de equipos para Ucrania; la liberación de Pablo González —detenido en Polonia por espionaje e incluido en el mayor canje de prisioneros desde la Guerra Fría— [13]; la detención en Barcelona de presuntos terroristas prorrusos organizando atentados en Europa [14]; y la captación de milicianos hispanohablantes para el frente ucraniano. Todos ellos necesitan un proceso previo de radicalización informativa que normalice la hostilidad hacia Occidente. España, con fracturas soberanistas activas y un ecosistema de izquierda latinoamericanista, ofrece puertos de atraque especialmente propicios para estas estrategias.

B. Oportunidades para la resiliencia informativa

@CasaReal se reveló como el principal actor de contranarración institucional positiva en Cuenca (1.887 RTs). Este capital simbólico debe activarse proactivamente para Madrid 2026, no limitarse a la cobertura protocolaria reactiva. Se recomienda: (1) establecer un observatorio de monitorización lingüístico-discursiva temprana —el corpus evidencia activación narrativa cuatro días antes del evento—; (2) desarrollar estrategias de pre-bunking que anticipen el encuadre BRICS-Iberoamérica antes de que lo active el ecosistema prorruso; (3) institucionalizar mecanismos de cooperación en resiliencia informativa como eje sustantivo de la agenda de Madrid 2026, articulando las capacidades de detección y respuesta de cada estado miembro; y (4) adaptar los sistemas de monitorización para detectar proxies ideológicos —perfil @AnibalGarzon— con la misma prioridad que los medios formales de Estado. El sesgo ecuatoriano (36,6%) anticipa que el ecosistema español tendrá un peso mucho mayor en 2026, con sus dinámicas de polarización doméstica plenamente activas.

VI. CONCLUSIONES

La XXIX Cumbre Iberoamericana de Cuenca es percibida en el espacio digital hispanohablante como un fracaso diplomático histórico, diagnóstico transversal a posicionamientos muy distintos y validado por medios internacionales de referencia. El corpus es sustancialmente orgánico; no se detectan bots ni operaciones artificiales sistemáticas. La única coordinación explícita identificada es la del aparato comunicacional cubano —transparente y estatal—. El hallazgo geopolíticamente más significativo es el Frame 5 y el argumento BRICS-Iberoamérica de @AnibalGarzon (1.518 RTs): conecta el fracaso puntual de Cuenca con la tendencia estructural de reconfiguración del poder mundial y cuestiona la capacidad de España de liderar un foro de 22 naciones en el nuevo contexto multipolar. Este argumento, operando sobre datos reales con un marco interpretativo sesgado, es el vector narrativo de mayor potencial de reactivación en Madrid 2026 y el más difícil de contrarrestar mediante fact-checking convencional. El choque Cuba-Argentina, que bloqueó la declaración final y generó el tweet más viral del corpus (2.404 RTs, @UHN_Plus), reproduce en el foro iberoamericano la fractura hemisférica que actores externos pueden instrumentalizar con bajo coste.

Este riesgo no puede analizarse de forma aislada del contexto de guerra híbrida en el espacio hispanohablante: los casos documentados ilustran que la radicalización informativa y la acción física son capas complementarias del mismo sistema. El traspaso de la Secretaría Pro Tempore convierte a España en garante de la continuidad del foro. El éxito o fracaso de Madrid 2026 será determinante para la supervivencia del foro como instrumento de política exterior española en América Latina. Se recomienda la implementación de un sistema de monitorización lingüístico-discursiva anticipada, estrategias de pre-bunking adaptadas al contexto iberoamericano, y la institucionalización de mecanismos de cooperación en resiliencia informativa en el marco de la propia Conferencia Iberoamericana.

REFERENCIAS

- [1] CESEDEN/IEEE: "Cuaderno de Estrategia 231: Los nuevos retos de seguridad y defensa en Iberoamérica", en Ministerio de Defensa, España, 2025.
- [2] M. B. Bernabé-Crespo: "Fronteras ocultas en la zona gris europea", en Geopolítica(s), vol. 11, n. 2, pp. 259-285, 2020.
- [3] A. Borràs Rius: "El desafío de las injerencias extranjeras en la era del ciberespacio en España", en Revista Temas, 2025.
- [4] Instituto Cervantes: "El español: lengua para el mundo 2025", en Observatorio Global del Español, 2025.
- [5] D. Huttenlocher, H. A. Kissinger y E. Schmidt: "La era de la inteligencia artificial y nuestro futuro humano", Anaya Multimedia, 2023.
- [6] BBC News Mundo: "México: Retroceso, la controversia página web sobre AMLO", en BBC News Mundo, 31 de mayo de 2018.
- [7] M. Marginedas: "México convierte plataforma en base de espionaje ruso", en El Periódico, 7 de agosto de 2024.
- [8] R. Sánchez del Vas et al.: "Análisis de la campaña de desinformación en las Elecciones Brasileñas de 2022", en Doxa Comunicación, n. 41, 2025.
- [9] A. Borràs Rius: "El proceso independentista en Cataluña (2010-2019)", tesis doctoral, UC3M, 2024.
- [10] R. M. Entman: "Framing: Toward clarification of a fractured paradigm", en Journal of Communication, vol. 43, n. 4, pp. 51-58, 1993.
- [11] EEAS: "3rd EEAS Report on Foreign Information Manipulation and Interference (FIMI) Threats", 2025.
- [12] A. Borràs Rius: "El mapa que explica la influencia rusa en España", en Agenda Pública, 28 de enero de 2025.

Plataforma escalable de autenticación continua basada en biometría del comportamiento y modelos de inteligencia artificial

Francisco J. Nóvoa
CIGUS CITIC – Universidade
da Coruña

Campus de Elviña s/n, 15071
A Coruña, Spain
francisco.javier.novoa@udc.es

Mario Casado
CIGUS CITIC – Universidade
da Coruña

Campus de Elviña s/n, 15071
A Coruña, Spain
mario.diez@udc.es

Daniel Garabato
CIGUS CITIC – Universidade
da Coruña

Campus de Elviña s/n, 15071
A Coruña, Spain
daniel.garabato@udc.es

Ignasi de José
Institut d'Estudis Espacials de
Catalunya (IEEC)

Esteve Terradas, 1, ed. RDIT,
PMT-UPC, 08860 Castelldefels
(Barcelona), Spain
ignasidj@icc.ub.edu

Álvaro Sarmiento
CIGUS CITIC – Universidade
da Coruña

Campus de Elviña s/n, 15071
A Coruña, Spain
alvaro.sarmiento@udc.es

Carlos Dafonte
CIGUS CITIC – Universidade
da Coruña

Campus de Elviña s/n, 15071
A Coruña, Spain
carlos.dafonte@udc.es

Resumen- Los mecanismos tradicionales de autenticación presentan limitaciones frente a ataques avanzados, lo que refuerza la necesidad de soluciones de autenticación continua. Este trabajo presenta una plataforma de autenticación basada en biometría del comportamiento basada en la dinámica del ratón y modelos de inteligencia artificial. La infraestructura propuesta integra captura de eventos en tiempo real, extracción de características y modelado del comportamiento en una arquitectura escalable y contenerizada. La evaluación experimental, realizada con usuarios reales en entornos no controlados, compara distintos algoritmos de aprendizaje automático bajo diferentes volúmenes de entrenamiento. Los resultados muestran que *CatBoost* y SVM ofrecen el mejor equilibrio entre precisión y capacidad de generalización, alcanzando mejoras progresivas hasta la saturación del rendimiento. Este artículo constituye un resumen extendido del trabajo publicado en el *23rd IEEE International Symposium on Network Computing and Applications (NCA 2025)*, donde se detallan la metodología y los resultados completos.

Index Terms- autenticación continua, inteligencia artificial, ciberseguridad, sistemas basados en colas.

Tipo de contribución: Investigación ya publicada

I. INTRODUCCIÓN

Los sistemas tradicionales de autenticación, basados en credenciales estáticas como contraseñas o *tokens*, presentan vulnerabilidades frente a técnicas avanzadas de *phishing*, robo de credenciales y suplantación de identidad. Aunque existen mecanismos multifactor y soluciones biométricas, estas últimas pueden implicar costes elevados, requisitos de hardware específico y consideraciones legales relacionadas con la gestión de datos sensibles. Además, determinadas características biométricas son irrevocables, lo que incrementa el riesgo en caso de compromiso.

Ante estas limitaciones, la autenticación continua proporciona una alternativa complementaria que permite verificar de forma dinámica la identidad del usuario durante toda la sesión activa. En este contexto, la biometría del comportamiento basada en la dinámica del ratón constituye una aproximación no intrusiva y fácilmente desplegable, capaz de capturar patrones individuales de interacción sin necesidad de dispositivos adicionales.

En este trabajo se presenta una plataforma de autenticación continua que integra la captura de eventos en tiempo real con la extracción del conjunto estructurado de características y el modelado mediante técnicas de aprendizaje automático, dentro de una arquitectura modular y contenerizada.

Uno de los aspectos más relevantes de esta infraestructura consiste en la adecuada selección del modelo o modelos de IA a utilizar. Para ello, se ha llevado a cabo una experimentación exhaustiva en la que se evalúa el rendimiento de distintos modelos de clasificación frente a diferentes volúmenes de entrenamiento, utilizando datos de usuarios reales en entornos no controlados.

Este artículo constituye un resumen extendido del trabajo publicado en el *23rd IEEE International Symposium on Network Computing and Applications (NCA 2025)* [1], donde se describen en detalle la arquitectura, la metodología experimental y el análisis completo de resultados.

II. ARQUITECTURA DE LA PLATAFORMA

La plataforma se diseñó como una infraestructura modular orientada a la autenticación continua en tiempo real, priorizando la escalabilidad, el desacoplamiento de componentes y la tolerancia a fallos. El sistema adopta un modelo cliente-servidor en el que una aplicación de escritorio captura los eventos de interacción del ratón y los transmite en

bloques al servidor a través de una API.

En el servidor, los eventos se gestionan mediante una arquitectura de procesamiento en *streaming* que separa la ingesta, el almacenamiento y la inferencia, mediante un sistema de mensajería distribuida que sigue el paradigma de desacoplamiento productor–consumidor, ampliamente adoptado en plataformas como Apache Kafka [2].

Este enfoque permite procesar datos de múltiples usuarios de forma concurrente manteniendo el orden temporal de los eventos. Los datos se almacenan de forma persistente para análisis posteriores, mientras que en paralelo se activan los módulos de extracción de características y predicción.

El sistema integra componentes especializados para el entrenamiento, almacenamiento y actualización de modelos, así como para la generación de inferencias en tiempo real durante la sesión activa del usuario. Todo el despliegue se realiza mediante contenedores Docker, garantizando portabilidad y facilitando su adaptación a distintos entornos de ejecución.

III. METODOLOGÍA EXPERIMENTAL

La evaluación experimental se llevó a cabo con diez usuarios que utilizaron la aplicación durante un mes en entornos no controlados, generando aproximadamente cuatro millones de eventos por usuario. Cada evento se registró como una tupla (x , y , $timestamp$) y se transmitió en bloques de 1.000 registros. Posteriormente, estos bloques se segmentaron en subconjuntos de 100 eventos para la extracción de características.

A partir de cada subconjunto, se calcularon 31 características de movimiento y temporales que describen la dinámica de interacción del usuario. El preprocesamiento incluyó la eliminación de valores atípicos mediante el método del rango intercuartílico, agregación estadística y normalización en el intervalo $[0,1]$, con el objetivo de estabilizar el entrenamiento de los modelos.

Se evaluaron cinco algoritmos supervisados: *CatBoost*, *Random Forest*, redes neuronales, árboles de decisión y *Support-Vector Machines (SVM)*. La optimización de hiperparámetros se realizó mediante *Randomized Search* con validación cruzada de cinco particiones, priorizando la precisión como métrica principal, con el objetivo de minimizar falsos positivos en el proceso de autenticación.

Los modelos se entrenaron con diferentes proporciones del conjunto de datos (1%, 10%, 20% y 30%) para analizar la evolución del rendimiento y detectar posibles puntos de saturación. Además, se realizó un test de rechazo incorporando un usuario no visto durante el entrenamiento, evaluando la capacidad del sistema para identificar accesos no autorizados.

IV. RESULTADOS Y DISCUSIÓN

La evaluación permitió analizar la evolución del rendimiento en función del volumen de datos de entrenamiento. Incluso con el 1% del conjunto disponible, los modelos alcanzan valores de precisión y *recall* superiores al 90%, lo que indica que la dinámica del ratón contiene información discriminativa suficiente incluso con datos limitados.

A medida que el volumen de entrenamiento aumenta al 10% y 20%, se observa una mejora progresiva en todas las métricas. *CatBoost* y *SVM* destacan de forma consistente,

alcanzando valores de F1 próximos a 0,98 con el 20% de los datos. Al incrementar hasta el 30%, la mejora es marginal, lo que sugiere la existencia de un punto de saturación a partir del cual el aumento de datos no produce ganancias significativas.

En el escenario de rechazo, incorporando un usuario no visto durante el entrenamiento, los modelos mantienen un comportamiento robusto. *CatBoost*, *Random Forest* y *SVM* alcanzan valores de F1 en torno a 0,92–0,93 con el 20%–30% de los datos, demostrando una adecuada capacidad para discriminar accesos no autorizados. En contraste, el árbol de decisión presenta una menor estabilidad y un rendimiento inferior, lo que indica mayor sensibilidad a la variabilidad del comportamiento.

En conjunto, los resultados confirman que los enfoques basados en *CatBoost* y *SVM* ofrecen el mejor equilibrio entre precisión, estabilidad y capacidad de generalización en autenticación continua basada en biometría del comportamiento.

V. CONCLUSIONES

La plataforma presentada demuestra la viabilidad de la autenticación continua basada en dinámica del ratón como mecanismo complementario a los sistemas tradicionales de verificación. La integración de la captura de datos en tiempo real, el procesamiento estructurado de las características y los modelos de aprendizaje automático dentro de una arquitectura modular y escalable, permite desplegar soluciones de monitorización basada en el comportamiento en entornos reales.

Los resultados obtenidos confirman que modelos como *CatBoost* y *SVM* ofrecen un elevado nivel de precisión y capacidad de generalización, alcanzando métricas próximas al 98% en escenarios de autenticación y manteniendo un comportamiento robusto en pruebas de rechazo. Asimismo, se observa un punto de saturación en torno al 20% del volumen de datos de entrenamiento, lo que sugiere que es posible obtener alto rendimiento sin requerir conjuntos masivos.

AGRADECIMIENTOS

Este trabajo ha sido financiado por el Ministerio de Ciencia e Innovación (MCIN/AEI/10.13039/501100011033) y por la Unión Europea a través del programa NextGenerationEU / PRTR (Ref. TED2021-130492B-C21). Asimismo, se agradece el apoyo de la Xunta de Galicia y de la Unión Europea mediante el Programa FEDER Galicia 2021–2027 (Refs. ED431B 2024/21 y ED431B 2024/02), así como del CITIC (Ref. ED431G 2023/01).

REFERENCIAS

- [1] F. J. Nóvoa, D. Garabato, M. Casado, I. De Jose and C. Dafonte, "Continuous behavioral authentication using mouse dynamics based on Artificial Intelligence," in *23rd International Symposium on Network Computing and Applications (NCA)*, Lisboa, 2025.
- [2] J. Kreps, N. Narkhede and J. Rao, "Kafka: A Distributed Messaging System for Log Processing," in *Proceedings of the NetDB Workshop*, Atenas, 2011.

Metataxonomía del factor humano en ciberseguridad alineada con estándares

Belén Sánchez Pardo, Jaime Pujante-Sáez, Ignacio Ruiz Chicano y José Luis Hernández-Ramos

Departamento de Ingeniería de la Información y las Comunicaciones

Universidad de Murcia

Murcia, España 30100

belen.sanchezp@um.es, jaime.pujantes@um.es, i.ruizchicano@um.es, jluis.hernandez@um.es

Resumen—La investigación sobre el factor humano en ciberseguridad ha recurrido a instrumentos heterogéneos y taxonomías basadas en enfoques cualitativos, lo que genera solapamientos terminológicos y dificulta la trazabilidad hacia controles y marcos de cumplimiento. Para abordar esta limitación, este trabajo propone una metataxonomía de comportamientos basada en un proceso sistemático y reproducible de integración de fuentes (HAIS-Q y SeBIS), que normaliza unidades conductuales, consolida redundancias y preserva la trazabilidad hacia los ítems originales. El resultado es una estructura de diez categorías (credenciales, dispositivos, phishing, manejo de información, parches, reporte de incidentes y uso seguro de IA), junto con su mapeo a estándares relevantes de ciberseguridad. Asimismo, se describe un entorno web instrumentado (en desarrollo) orientado a elicitar y registrar comportamientos observables para su validación con datos reales de usuarios.

Index Terms—Comportamientos de ciberseguridad; Factor humano; Metataxonomía; Estandarización en Ciberseguridad

Tipo de contribución: Investigación en desarrollo

I. INTRODUCCIÓN

El factor humano sigue siendo un determinante clave del riesgo en ciberseguridad [1], ya que las decisiones individuales influyen en la exposición a amenazas como phishing, ingeniería social o uso indebido de credenciales. Informes como el DBIR 2024 señalan que muchas brechas incluyen un elemento humano no malicioso¹. En esta línea, iniciativas como el Human-Centered Cybersecurity del NIST promueven enfoques basados en datos empíricos². En la última década han surgido instrumentos para medir comportamientos de seguridad, como HAIS-Q [2], SeBIS [3], CCSB [4] y RScB [5], junto con repositorios como SebDB [6]. Sin embargo, estos enfoques se basan en autoinformes, lo que introduce sesgos y discrepancias entre la intención y el comportamiento real [7]. Esta brecha, conocida como la “paradoja de la privacidad” [8], limita la capacidad de inferir conductas observables [9]. Además, los instrumentos presentan fragmentación, caracterizada por heterogeneidad terminológica, baja interoperabilidad y falta de trazabilidad hacia marcos como ISO/IEC 27002:2022 [10] o NIST CSF 2.0 [11], lo que dificulta su aplicación en la gestión del riesgo y el cumplimiento. Para abordar estas limitaciones, este trabajo propone una metataxonomía de comportamientos como capa de interoperabilidad entre la medición académica y la práctica organizativa. La propuesta integra múltiples fuentes con trazabilidad a los ítems originales, establece un mapeo

inicial a estándares y describe un entorno web instrumentado para capturar comportamientos observables y su validación empírica.

Las principales contribuciones de este trabajo son:

- Identificación de la brecha entre la medición psicométrica y su uso operativo.
- Integración de fuentes heterogéneas (HAIS-Q, SeBIS, SebDB).
- Propuesta de una metataxonomía de diez categorías con trazabilidad.
- Mapeo a ISO/IEC 27002:2022 y NIST CSF 2.0.
- Diseño de un entorno de simulación para la validación empírica.

II. TRABAJOS RELACIONADOS

La investigación sobre el comportamiento humano en ciberseguridad ha dado lugar a múltiples enfoques heterogéneos en términos de unidades de análisis, métodos de medida y objetivos, lo que genera fragmentación y limita la interoperabilidad y la trazabilidad hacia estándares.

Taxonomías conceptuales: clasifican comportamientos según la intencionalidad o el contexto, pero operan a alto nivel y sin trazabilidad operativa [4], [12], [13], [14].

Escalas psicométricas: instrumentos como HAIS-Q o SeBIS miden comportamientos mediante autoinforme, lo que introduce sesgos y dificulta su traducción a acciones observables [2], [3], [5], [15], [8].

Repositorios operativos: propuestas como SebDB recopilan conductas concretas, pero carecen de un marco unificado y de una alineación con estándares [6]. Estos enfoques presentan limitaciones comunes:

- Fragmentación semántica entre enfoques
- Dependencia del autoinforme
- Falta de trazabilidad a estándares (ISO/NIST)

III. PROCESO DE CONSTRUCCIÓN DE LA META-TAXONOMÍA

III-A. Enfoque metodológico

La metataxonomía se construyó mediante un proceso iterativo de integración de tres fuentes heterogéneas: HAIS-Q y SeBIS, como instrumentos validados de autoinforme, y SebDB, como repositorio de comportamientos observables. La selección buscó combinar diversidad conceptual y nivel de granularidad, cubriendo desde escalas psicométricas hasta catálogos de conductas concretas. Como trabajo futuro, se prevé la ampliación de la integración con otras fuentes relevantes del ecosistema, como RScB y CCSB, lo que permitiría

¹<https://www.verizon.com/about/news/2024-data-breach-investigations-report-vulnerability-exploitation-boom>

²<https://www.nist.gov/programs-projects/human-centered-cybersecurity>

Tabla I
MAPEO DE LAS CATEGORÍAS DE LA METATAXONOMÍA CON HAIS-Q, SeBIS, SeBDB, ISO/IEC 27002:2022 Y NIST CSF 2.0.

Categoría	HAIS-Q	SeBIS	SeBDB	ISO/IEC 27002:2022	NIST CSF 2.0
1. Gestión de contraseñas y Autenticación	<i>Gestión de contraseñas</i>	<i>Generación de contraseñas</i>	<i>Autenticación y control de acceso</i>	5.16 (Identity management), 5.17 (Authentication information), 8.5 (Secure authentication)	PR.AA (Protect – Identity Management, Authentication, and Access Control)
2. Aseguramiento del dispositivo y Seguridad física	<i>Computación móvil, Manejo de la información</i>	<i>Aseguramiento del dispositivo</i>	<i>Seguridad del dispositivo y Seguridad física</i>	7.8 (Equipment protection), 8.1 (User endpoint devices), 8.7 (Malware protection)	PR.PS (Platform Security), PR.AA (Access Control)
3. Phishing y Uso seguro del correo electrónico	<i>Uso del correo electrónico</i>	<i>Concienciación proactiva</i>	<i>Prácticas seguras en línea y Comunicación</i>	5.14 (Awareness), 8.7 (Malware protection)	PR.AT (Awareness and Training), PR.DS (Data Security)
4. Navegación segura y Descargas	<i>Uso de Internet</i>	<i>Concienciación proactiva</i>	<i>Seguridad y manejo de datos / Prevención de amenazas</i>	8.23 (Web filtering), 8.7 (Malware protection), 8.19 (Installation of software)	PR.PT (Protective Technology), PR.DS (Data Security)
5. Redes sociales y Protección de información personal	<i>Redes sociales</i>	—*	<i>Prácticas seguras en línea y Comunicación</i>	5.10 (Acceptable use), 5.34 (Privacy and PII protection)	PR.DS (Data Security), GV.PO (Política)
6. Manejo seguro de información y Protección de datos	<i>Manejo de la información</i>	—*	<i>Seguridad y manejo de datos</i>	5.12 (Information classification), 5.13 (Labelling), 8.12 (Data leakage prevention), 5.34 (Privacy)	PR.DS (Data Security), GV.PO (Política)
7. Actualización de software y Gestión de parches	—*	<i>Actualización</i>	<i>Seguridad del dispositivo / Prevención de amenazas</i>	8.8 (Management of technical vulnerabilities), 8.19 (Installation of software)	PR.PS (Platform Security)
8. Notificación de incidentes y Respuesta	<i>Notificación de incidentes</i>	<i>Concienciación proactiva</i>	<i>Respuesta a incidentes y Notificación</i>	5.24 (Event reporting), 5.25 (Assessment), 5.26 (Response)	RS.CO (Response Communication), RS.MA (Mitigation Actions), DE.CM (Detection and Monitoring)
9. Concienciación y Cumplimiento de políticas	Modelo K-A-B completo	Orientado a intención conductual	<i>Concienciación, políticas y ayuda</i>	5.1 (Policies), 5.14 (Awareness)	PR.AT (Awareness and Training), GV.PO (Governance – Policies)
10. Uso seguro de sistemas de inteligencia artificial	—*	—*	—*	No existe control específico en ISO/IEC 27002:2022; posible alineación indirecta con principios de uso aceptable y protección de datos.	No existe categoría explícita en NIST CSF 2.0; posible relación indirecta con PR.DS (Data Security), GV.PO (Governance).

* No existe correspondencia explícita en la fuente.

enriquecer la cobertura de la metataxonomía y refinar las correspondencias con los estándares. La integración se realizó a nivel de dominio aplicando criterios de *equivalencia funcional*, *objeto de acción* y *coherencia semántica*, priorizando el significado conductual frente a diferencias terminológicas. A partir de los dominios resultantes se definieron categorías meta-taxonómicas y tareas instrumentables orientadas a elicitarse comportamientos observables y la obtención de evidencias cuantitativas del factor humano.

III-B. Categorías

Se definen diez categorías meta-taxonómicas. A continuación, se presentan las definiciones correspondientes.

- 1. Gestión de contraseñas y autenticación.** Prácticas orientadas al manejo seguro de credenciales y a la verificación de la identidad. Incluye contraseñas robustas, almacenamiento seguro, no reutilización, así como autenticación multifactor (MFA).
- 2. Aseguramiento del dispositivo y seguridad física.** Controles técnicos y físicos orientados a proteger dispositivos frente a accesos no autorizados. Incluye bloqueo de pantalla, autenticación, cifrado de disco, configuración de interfaces (Wi-Fi, Bluetooth, puertos) y protección física.
- 3. Phishing y uso seguro del correo electrónico.** Prácti-

cas orientadas a identificar intentos de suplantación y evitar la divulgación de información sensible. Incluye verificación de enlaces y remitentes, adjuntos sospechosos, reporte de mensajes fraudulentos y mecanismos anti-phishing.

4. **Navegación segura y descargas.** Hábitos orientados a minimizar la exposición a sitios maliciosos y software potencialmente dañino. Incluye verificación de sitios, uso de HTTPS, actualización del navegador y herramientas antimalware.
5. **Redes sociales y protección de información personal.** Prácticas orientadas a la protección de información personal en plataformas sociales.
6. **Manejo seguro de la información y protección de datos.** Prácticas orientadas a la protección de datos confidenciales a lo largo de su ciclo de vida.
7. **Actualización de software y gestión de parches.** Prácticas orientadas a la gestión de actualizaciones para corregir vulnerabilidades.
8. **Notificación de incidentes y respuesta.** Conductas orientadas a la detección, notificación y respuesta ante incidentes. Incluye reporte de anomalías, comunicación de brechas y colaboración en la respuesta.
9. **Concienciación y cumplimiento de políticas.** Conocimiento y cumplimiento de políticas de seguridad organizacionales. Incluye formación, adhesión a protocolos y no elusión de controles.
10. **Uso seguro de sistemas de inteligencia artificial.** Prácticas orientadas al uso responsable de herramientas de IA, minimizando riesgos. Incluye evitar datos sensibles, validación de resultados y evaluación de impactos en seguridad y privacidad.

III-C. Operacionalización en unidades conductuales

En este contexto, una *unidad conductual* corresponde a una acción humana observable y evaluable que impacta directa o indirectamente en la postura de seguridad. Tras la consolidación de la estructura general de la metataxonomía, se inició una segunda fase orientada a aumentar la granularidad mediante el desglose de cada categoría en unidades conductuales discretas. El procedimiento incluye:

- Extracción de ítems originales asociados a cada núcleo.
- Reformulación en formato de acción explícita.
- Descomposición de enunciados compuestos.
- Consolidación de redundancias semánticas intra e inter-instrumento.
- Registro de la trazabilidad hacia la fuente original.

Ejemplo ilustrativo dentro del núcleo “Gestión de contraseñas y autenticación”. El núcleo agrupa comportamientos relacionados con credenciales y mecanismos de verificación de identidad. Los ítems originales procedentes de escalas psicométricas suelen combinar múltiples dimensiones en un mismo enunciado. Considérese el siguiente ítem derivado de SeBIS: “*Activaría autenticación de dos factores siempre que esté disponible.*” Aunque este enunciado pertenece al núcleo de autenticación, incorpora varias acciones implícitas: configuración inicial, selección del método y uso del segundo factor. Para obtener unidades observables y evaluables, el enunciado se descompone en:

- Activación voluntaria de autenticación multifactor en cuentas corporativas.
- Selección de un método robusto de segundo factor (p.ej., aplicación autenticadora frente a SMS).
- Uso consistente del segundo factor durante la autenticación.
- No desactivación deliberada del mecanismo tras su configuración.

La implementación del entorno de simulación instrumenta únicamente aquellas unidades observables de forma inmediata en escenarios controlados. Esto permite medición independiente, mayor granularidad analítica y una alineación más precisa con controles normativos.

III-D. Mapeo normativo

Para aportar trazabilidad normativa, las categorías se alinearon con ISO/IEC 27002:2022 y NIST CSF 2.0 mediante correspondencias funcionales a nivel categorial. Este mapeo conecta el comportamiento humano con los controles técnico-organizativos, facilitando la interpretación de los resultados en contextos de cumplimiento y gestión del riesgo. La Tabla I resume las principales correspondencias. La categoría 10 (uso seguro de sistemas de IA) no presenta alineación explícita en estos marcos, lo que evidencia una laguna normativa en el tratamiento conductual del uso de IA, relevante dado su creciente protagonismo en entornos organizativos.

IV. ENTORNO DE SIMULACIÓN CONDUCTUAL

Como extensión operativa, se ha desarrollado un entorno web de simulación orientado a elicitar y registrar el comportamiento en escenarios controlados alineados con la metataxonomía. Su objetivo no es la formación, sino la observación estructurada de decisiones y acciones para obtener evidencias cuantitativas del factor humano. El sistema presenta situaciones contextualizadas (p.ej., autenticación, navegación, descarga o gestión de información) en las que el usuario realiza acciones observables. Cada interacción se vincula a unidades conductuales previamente definidas, permitiendo registrar métricas como elecciones, acciones completadas y secuencias de pasos. La Figura 1 muestra ejemplos representativos: la creación de credenciales, la descarga de recursos, la selección de MFA y el cierre de sesión. Estos escenarios se corresponden respectivamente con las categorías 1 (gestión de contraseñas y autenticación), 4 (navegación segura y descargas), 1 (gestión de contraseñas y autenticación) y 6 (manejo seguro de la información) de la metataxonomía, permitiendo analizar decisiones observables del usuario de forma directamente trazable a la estructura propuesta.

V. CONCLUSIONES Y TRABAJO FUTURO

Este trabajo presenta una metataxonomía conductual que aborda la brecha entre la medición psicométrica y el uso operativo en ciberseguridad. Mediante la integración de fuentes heterogéneas (HAIS-Q, SeBIS y SebDB), se propone una estructura de diez categorías con trazabilidad hacia los ítems originales, actuando como capa de interoperabilidad entre escalas psicométricas, repositorios operativos y marcos normativos. El mapeo a ISO/IEC 27002:2022 y NIST CSF 2.0 establece correspondencias funcionales preliminares que facilitan su aplicación en contextos de cumplimiento y gestión



Figura 1. Ejemplos de escenarios del entorno de simulación conductual

del riesgo. La categoría que se define como el uso seguro de IA generativa y modelos de lenguaje no presenta correspondencia explícita en estos marcos, lo que evidencia una laguna conductual aún poco cubierta por estándares generalistas, a diferencia de marcos específicos como el AI RMF 1.0, centrados en la gobernanza de sistemas de IA. Como trabajo futuro, se plantea la validación empírica mediante el entorno de simulación, así como el refinamiento metodológico a nivel de unidad conductual, incorporando métricas de cobertura y redundancia normativa.

AGRADECIMIENTOS

Este estudio ha sido financiado por el proyecto CNS2023-145059 (INTEGRATOR), financiado por

MICIU/AEI/10.13039/501100011033 y la Unión Europea NextGenerationEU/PRTR.

REFERENCIAS

- [1] A. Pollini, T. C. Callari, A. Tedeschi, D. Ruscio, L. Save, F. Chiarugi, and D. Guerri, "Leveraging human factors in cybersecurity: an integrated methodological approach," *Cognition, Technology & Work*, vol. 24, no. 2, pp. 371–390, 2022. [Online]. Available: <https://doi.org/10.1007/s10111-021-00683-y>
- [2] K. Parsons, A. McCormac, M. Butavicius, M. Pattinson, and C. Jerram, "Determining employee awareness using the human aspects of information security questionnaire (hais-q)," *Computers & Security*, vol. 42, 05 2014. [Online]. Available: <https://www.sciencedirect.com/science/article/abs/pii/S016740481300179X>
- [3] S. Egelman and E. Peer, "Scaling the security wall developing a security behavior intentions scale (sebis)," in *Proceedings of the 33rd annual ACM conference on human factors in computing systems*, 04 2015. [Online]. Available: <https://dl.acm.org/doi/10.1145/2702123.2702249>
- [4] P. Ifinedo and B. A. Akinuwa, "Employees' non-malicious, counterproductive computer security behaviors (ccsb) in nigeria and canada: An empirical and comparative analysis," in *2014 IEEE 6th International Conference on Adaptive Science & Technology (ICAST)*, 2014, pp. 1–7. [Online]. Available: <https://ieeexplore.ieee.org/document/7068109>
- [5] L. Hadlington, "Human factors in cybersecurity: Examining the link between internet addiction, impulsivity, attitudes towards cybersecurity, and risky cybersecurity behaviours," *Heliyon*, vol. 3, no. 7, p. e00346, 2017. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S2405844017309982>
- [6] CybSafe. (2025) Security behaviour database (sebdb). [Online]. Available: <https://www.sebdb.com/>
- [7] R. McGregor, C. Reaiche, S. Boyle, and G. C. de Zubielqui, "Consumer perceptions of personal cyber awareness, knowledge, and risk," *Journal of Cybersecurity*, vol. 11, no. 1, 2025. [Online]. Available: <https://academic.oup.com/cybersecurity/article/11/1/tyaf029/8361918>
- [8] S. Kokolakis, "Privacy attitudes and privacy behaviour: A review of current research on the privacy paradox phenomenon," *Computers & security*, vol. 64, pp. 122–134, 2017. [Online]. Available: <https://www.sciencedirect.com/science/article/abs/pii/S0167404815001017>
- [9] I. Arend, A. Shabtai, T. Idan, R. Keinan, and Y. Bereby-Meyer, "Passive-and not active-risk tendencies predict cyber security behavior," *Computers & Security*, vol. 97, p. 101964, 2020.
- [10] ISO/IEC 27002:2022 *Information technology — Security techniques — Code of practice for information security controls*, International Organization for Standardization and International Electrotechnical Commission Std., ISO/IEC Standard. [Online]. Available: <https://www.iso.org/standard/75652.html>
- [11] National Institute of Standards and Technology, "The NIST Cybersecurity Framework (CSF) 2.0," 2024. [Online]. Available: <https://www.nist.gov/cyberframework>
- [12] J. Kälvrestad, F. Burvall, and M. Nohlberg, "A taxonomy of factors that contribute to organizational cybersecurity awareness (csa)," *Information & Computer Security*, vol. 33, no. 2, pp. 141–160, 2025. [Online]. Available: <https://www.emerald.com/ics/article/33/2/141/1263425/A-taxonomy-of-factors-that-contribute-to>
- [13] T. Mashiane and E. Kritzinger, "Cybersecurity behaviour: A conceptual taxonomy," in *Information Security Theory and Practice: 12th IFIP WG 11.2 International Conference, WISTP 2018, Brussels, Belgium, December 10–11, 2018, Revised Selected Papers*. Berlin, Heidelberg: Springer-Verlag, 2018, p. 147–156. [Online]. Available: https://doi.org/10.1007/978-3-030-20074-9_11
- [14] D. Baltutis, T. Teubner, and M. T. Adam, "A typology of cybersecurity behavior among knowledge workers," *Computers & Security*, vol. 140, p. 103741, 2024. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0167404824000427>
- [15] K. Kannelønning and S. Katsikas, "A systematic literature review of how cybersecurity-related behavior has been assessed," *Information & Computer Security*, vol. 31, 04 2023. [Online]. Available: <https://www.emerald.com/ics/article/31/4/463/111532/A-systematic-literature-review-of-how>

Desafíos de la Ciberseguridad OT en la Era NIS2: Amenazas, IA y Brechas de Implementación

Farid Bagheri-Gisour Marandyn, Néstor Rodríguez Pérez, Álvaro Jesús López López,
Juan Atanasio Carrasco Mateos, Agustín Valencia Gil-Ortega, Javier Jarauta Sánchez,
Rafael Palacios, José Antonio Rodríguez Mondéjar, Gregorio López López
Instituto de Investigación Tecnológica (IIT)
Universidad Pontificia Comillas, ICAI
Madrid, España
Email: fbagherigisour@comillas.edu

Tipo de contribución: Investigación original (4 páginas).

Resumen—La Directiva NIS2 y su ecosistema asociado (CRA, AI Act) imponen requisitos de detección, respuesta y gestión de vulnerabilidades que el dominio OT aún no ha madurado. Esta revisión estructurada de la literatura reciente identifica un cuello de botella común: la brecha entre validación sintética y entornos reales bloquea simultáneamente la adopción operativa de IA y el cumplimiento práctico de NIS2. Las precisiones superiores al 99 % reportadas en datasets públicos no se traducen en despliegue, y solo el 13 % de las vulnerabilidades del catálogo KEVC relevantes para OT ofrecen alternativas al parcheo aplicables a sistemas que no admiten interrupción. Se argumenta que los laboratorios OT que integran hardware industrial real, honeypots y gemelos digitales constituyen la infraestructura imprescindible para cerrar estas brechas.

Index Terms—Ciberseguridad OT, ICS, SCADA, NIS2, inteligencia artificial, honeypots, testbeds, IEC 62443, gemelo digital.

I. INTRODUCCIÓN

La Directiva NIS2 [1], en vigor desde enero de 2023 con plazo de transposición en octubre de 2024, ha marcado un punto de inflexión para la ciberseguridad de las infraestructuras críticas europeas. Los operadores de sectores esenciales están obligados a implementar gestión de riesgos, notificación de incidentes en 24/72 horas y seguridad de la cadena de suministro, con sanciones de hasta el 2 % de la facturación global. Este marco se complementa con el Cyber Resilience Act (CRA) [2], que exige seguridad por diseño a los fabricantes de productos digitales incluidos PLCs y sensores IoT, y con el AI Act [3], que puede encuadrar como alto riesgo los sistemas de IA desplegados en infraestructuras críticas según su contexto de uso. La convergencia configura un ecosistema normativo sin precedentes que el dominio OT, históricamente aislado, no está preparado para cumplir.

La urgencia regulatoria responde a un panorama de amenazas en rápida evolución y a una asimetría estructural propia del dominio. Los entornos OT acumulan dispositivos con ciclos de vida de hasta dos décadas, protocolos como Modbus, DNP3 u OPC Classic sin cifrado ni autenticación nativa, y procesos físicos que no admiten interrupción para aplicar parches; la convergencia IT/OT ha expuesto a estos sistemas a las vulnerabilidades del dominio IT sin disponer de los mismos mecanismos de defensa ni de ventanas de mantenimiento equivalentes [4]. Los informes de industria documentan un incremento del 84 % en ataques con protocolos OT [5],

vulnerabilidades nuevas en OPC UA [6] y la explotación de memoria en PLCs [7], con MaDIoT alcanzando su tercera generación [8].

Frente a surveys recientes centrados en amenazas [4] o en IA/ML [9], este artículo presenta una revisión estructurada que articula cuatro ejes (amenazas, defensas, IA/ML y estándares), complementados con tendencias emergentes y brechas identificadas, para responder: *¿cómo se distribuye el esfuerzo investigador en ciberseguridad OT bajo NIS2 y dónde están las brechas que bloquean el cumplimiento operativo?* La tesis defendida es que el cuello de botella común a la adopción de IA, la gestión de vulnerabilidades y la validación de defensas es la falta de infraestructura realista de experimentación, y que los laboratorios OT que integran hardware industrial real, gemelos digitales y honeypots, como el CiberLab de ICAI [10], constituyen la respuesta operativa a esta brecha.

II. METODOLOGÍA

Se ha seguido un proceso estructurado inspirado en PRISMA. Las fuentes consultadas incluyen IEEE Xplore, ACM DL, ScienceDirect, USENIX, Springer y arXiv (2023–2025), complementadas con informes de industria (ENISA, Forescout, Honeywell, Dragos), regulaciones europeas (NIS2, CRA, AI Act, Network Code) y guías técnicas (NIST SP 800-82, IEC 62443, MITRE ATT&CK for ICS). Los criterios de inclusión exigen relevancia explícita para entornos OT/ICS, publicación en venues reconocidos y aportación técnica verificable; se excluyen trabajos exclusivamente IT y preprints sin resultados reproducibles. El corpus resultante se clasifica en seis categorías no excluyentes: contexto OT/ICS, panorama de amenazas, estrategias de defensa, IA/ML aplicada, estándares y gobernanza, y tendencias emergentes.

III. ESTADO DEL ARTE

III-A. Panorama de amenazas y vectores de ataque

APT y panorama industrial. El panorama de amenazas en OT ha experimentado una transformación significativa [4], [11]: Bhole et al. [12] analizan 120 grupos APT y MITRE ATT&CK for ICS [13] formaliza sus tácticas. Los informes de industria, cuyos datos hay que interpretar con cautela, convergen en la magnitud: ENISA [14] analiza 4.875 incidentes en su panorama 2025, Forescout/Vedere Labs [5] documenta el 84 % de incremento en ataques con protocolos OT (Modbus el más explotado) y Honeywell [15] sitúa al USB como

vector del 51 % del malware industrial. **Vulnerabilidades en dispositivos.** Los ataques MaDIoT han alcanzado su tercera generación coordinando recursos energéticos distribuidos [8], [16]; la sistematización de López-Morales et al. [17] sobre PLCs identifica superficies de ataque inexploradas, demostradas empíricamente por Jo y Ahmed [7] (CVE-2024-11737) y por Diemunsch et al. [6] con 8 vulnerabilidades nuevas en OPC UA mediante análisis formal con ProVerif.

III-B. Estrategias de defensa y detección

La detección de intrusiones combina enfoques basados en estado y datos. Abbas et al. [18] introducen SAIN, invariantes conscientes del estado del PLC con solo 2 % de falsos positivos, mientras que Algul et al. [19] presentan SCADANet ante la falta de realismo de los datasets existentes. Villa et al. [20] aportan ICSQuartz, el primer fuzzer nativo para Structured Text consciente del ciclo de escaneo del PLC. En el plano post-incidente, Ike et al. [21] presentan PhyLink, una técnica forense que vincula evidencia física con vectores de infección logrando 98,7 % de precisión, mientras que Zhang et al. [22] demuestran HoneyParser sobre datos de honeypots SCADA desplegados en AWS. Un desafío transversal es la validación realista de las defensas: SCASS [23] integra PLCs ABB con virtualización, MiniCPS [24] combina SDN con emulación de procesos físicos para evaluar defensas MTD, y Crabb et al. [25] contenerizan gemelos digitales en Kubernetes. Ortiz et al. [26] muestran que el tráfico SCADA real desmiente los modelos sintéticos de comportamiento monolítico.

III-C. IA/ML aplicada a seguridad OT

La aplicación de IA/ML supera el 90 % de precisión en datasets de referencia [9]: Yalçın et al. [27] alcanzan 99,99 % con XGBoost (multiclase) en WUSTL-IIOT-2021 y Mesadieu et al. [28] obtienen 99,36 % mediante DRL (binario) sobre el mismo benchmark; las cifras no son comparables (paradigmas y granularidades distintos) y, junto con particiones favorables y la ausencia de *F1-score* ponderado o AUC-ROC, inflan la apariencia de robustez frente a entornos reales [9]. Fung et al. [29] revelan que los operadores luchan más con el diagnóstico de alarmas que con la detección, y Koay et al. [30] confirman que la adopción real permanece limitada por desafíos de datos y confianza. El aprendizaje federado [31] preserva la privacidad de los datos industriales, una capacidad especialmente relevante para operadores NIS2. En el frente autónomo, el agente CAI de Mayoral-Vilches et al. [32] resolvió 32 de 34 retos del Dragos OT CTF 2025, un 37 % más rápido que equipos humanos, anticipando el doble filo de los LLMs en OT.

III-D. Estándares y marco regulatorio

La Directiva NIS2 [1], aplicable desde octubre de 2024, cubre 18 sectores e impone notificación de incidentes en 24/72 horas, responsabilidad personal de la dirección y sanciones de hasta el 2 % de la facturación global. El Cyber Resilience Act [2] regula al *fabricante*: seguridad por diseño, gestión de vulnerabilidades durante todo el ciclo de vida y marcado CE de ciberseguridad para dispositivos IoT/OT. El AI Act [3] puede encuadrar como *alto riesgo* los IDS basados en IA/ML en infraestructuras críticas según su contexto de uso, exigiendo robustez, trazabilidad y supervisión humana. A nivel sectorial,

el Network Code on Cybersecurity [33] establece la primera regulación específica de ciberseguridad OT para flujos eléctricos transfronterizos. La guía NIST SP 800-82 Rev. 3 [34] y MITRE ATT&CK for ICS [35] siguen siendo las referencias técnicas centrales. Nilsson [36] identifica convergencia entre NIS2/CRA e IEC 62443 en seguridad del ciclo de vida pero brechas en vigilancia post-mercado y divulgación coordinada de vulnerabilidades.

La Tabla I resume una selección de contribuciones técnicas representativas, ilustrando la diversidad metodológica del campo (testbed real, dataset público, verificación formal, simulación, competición).

IV. ANÁLISIS Y TENDENCIAS

IV-A. Distribución temática y validación

La codificación del corpus (categorías no excluyentes, Tabla II) revela un sesgo claro: defensas y amenazas dominan frente a IA/ML aplicada y, sobre todo, estándares y gobernanza, evidenciando un desacoplamiento entre la urgencia normativa NIS2/CRA/AI Act y la atención académica. De los 47 trabajos con componente experimental, el 53 % se valida con datasets públicos o simulación y solo el 38 % sobre hardware industrial real (SCASS [23], SAIN [18], ICS-Quartz [20], PhyLink [21], Jo y Ahmed [7], AutoLabel [38]); la concentración de IDS validados sobre datasets contrasta con la escasez de testbeds reales para resiliencia y prevención [23], [25], [39], en línea con la falta de realismo de los datasets SCADA existentes [19].

IV-B. Brechas de investigación

Validación realista. Ortiz et al. [26] demuestran que las redes SCADA reales exhiben comportamientos que los modelos sintéticos no capturan; los testbeds híbridos [23], gemelos digitales [25] y plataformas SDN [24] avanzan en esa dirección sin replicar aún una infraestructura en producción, mientras los honeypots industriales [22] y los gemelos digitales adaptativos [37] la complementan capturando ataques reales. Akinremi et al. [40] confirman además una brecha de competencias IT/OT que laboratorios con hardware multi-generación y arquitectura Purdue, como el CiberLab de ICAI [10], permiten cerrar como plataforma de validación y formación.

Gestión de vulnerabilidades. El 65 % de las entradas del KEVC son relevantes para OT pero solo el 13 % admiten alternativas al parcheo [41]; NIS2 [1] obliga a gestionarlas activamente pese a la imposibilidad de detener procesos críticos, una paradoja que el CRA [2] aborda parcialmente trasladando al fabricante el ciclo de vida y las actualizaciones de seguridad. La alerta de CISA sobre los dispositivos Hitachi Energy FOX61x [42] ilustra la paradoja en la práctica: la mitigación exige cambios de configuración que requieren ventanas de mantenimiento planificadas, incompatibles con las ventanas de notificación 24/72 horas que NIS2 impone.

Adopción de IA. Las precisiones superiores al 99 % [27], [28] no se traducen en adopción: la interpretabilidad insuficiente y el escepticismo de los operadores [29], [30] pesan más que el rendimiento, mientras los ataques adversarios transferibles [43], el *concept drift* [44] y la falta de interoperabilidad [45] añaden riesgos que el AI Act [3] exigirá gestionar;

Tabla I
SELECCIÓN DE CONTRIBUCIONES TÉCNICAS REPRESENTATIVAS DEL CORPUS

Referencia	Técnica	Contribución principal	Protocolo	Validación ¹
Abbas et al. [18]	Invariantes de estado	Detección de ataques sigilosos con 2 % FP	PLC (ST)	Testbed real
Villa et al. [20]	Fuzzing nativo	Primer fuzzer ST consciente del ciclo de escaneo	Structured Text	Testbed real
Diemunsch et al. [6]	Verificación formal	8 vulnerabilidades nuevas en OPC UA	OPC UA	ProVerif
Ike et al. [21]	Forense ciberfísico	Vinculación síntomas físicos-intrusión (98,7 %)	Modbus	Testbed real
Mayoral-Vilches et al. [32]	Agente IA autónomo	Top-10 en Dragos OT CTF (32/34 retos)	Modbus, DNP3	Competición real
Alcaraz et al. [37]	Gemelo digital adaptativo	Protección, engaño y testeo integridad	IIoT	Simulación

Tabla II
DISTRIBUCIÓN DEL CORPUS ACADÉMICO POR CATEGORÍA (NO EXCLUYENTES)

Categoría	N.º trabajos
Defensas y detección	53
Amenazas y vectores	35
IA/ML aplicada	28
Contexto OT/ICS	20
Estándares y gobernanza	8
Tendencias emergentes	3

el aprendizaje federado [31] emerge como vía para entrenar modelos sin centralizar datos de infraestructuras críticas.

IV-C. Tendencias emergentes

IA generativa y agentes autónomos. CAI [32] resolvió 32/34 retos del Dragos OT CTF un 37 % más rápido que equipos humanos, anticipando que los LLMs transformarán ofensiva y defensa: automatización de reglas, análisis de logs [38] y grafos de procedencia CTI [46]. El AI Act [3] exigirá robustez adversarial y supervisión humana en un escenario donde Meskini et al. [43] demuestran la transferibilidad de evasiones contra IDS IIoT y Lara-Gutiérrez et al. [44] abordan el *concept drift* con reentrenamientos mínimos. **Gemelos digitales, honeypots y engaño.** Alcaraz et al. [37] integran protección, *deception* y testeo en un gemelo adaptativo; Zhang et al. [22] capturan ataques reales con honeypots SCADA; Arias et al. [47] y Alcaraz y López [48] acoplan gemelos digitales con SIEM y detección de anomalías. Laboratorios OT que combinan hardware real, gemelos digitales y honeypots, como el CiberLab de ICAI [10], son la infraestructura imprescindible para validar defensas y formar profesionales IT/OT [23], [49]. **Expansión del perímetro.** La superficie de ataque se diversifica hacia 5G/Industry 5.0 [50], vehículos conectados [51], manufactura aditiva [52] y la cadena de suministro regulada por el CRA mediante SBOM [2], [53].

V. CONCLUSIONES

La revisión confirma tres conclusiones alineadas con la tesis. (1) **Amenazas y regulación divergen del estado de la práctica.** La sofisticación de los ataques (MaDIoT 3.0 [8], explotación de memoria en PLCs [7], vulnerabilidades en OPC UA [6], +84 % en protocolos OT [5]) y la convergencia

NIS2/CRA/AI Act/Network Code [1]–[3], [33] no encuentran respuesta en herramientas maduras: persisten brechas en vigilancia post-mercado [36] y solo el 13 % de entradas KEVC ofrecen alternativas al parcheo [41], exigiendo migrar de parches a mitigación compensatoria. (2) **La IA/ML supera el 99 % en datasets [27] pero no se adopta** por interpretabilidad insuficiente, vulnerabilidad adversaria [43], *concept drift* [44] y diagnóstico de alarmas [29]; los criterios de evaluación deben incorporar operabilidad y latencia más allá de la precisión, y los LLMs autónomos [32] emergen como doble filo. (3) **El cuello de botella común es la validación realista:** honeypots industriales [22], testbeds híbridos [23] y gemelos digitales adaptativos [37] convergen en una infraestructura de experimentación y engaño que cierra simultáneamente la brecha de IA, la de gestión de vulnerabilidades y la formación IT/OT [49].

De estas conclusiones se derivan tres implicaciones para la práctica: los criterios de evaluación de IDS deben incorporar operabilidad, latencia y diagnóstico de alarmas más allá de la precisión [29], [54]; la gestión de vulnerabilidades debe migrar hacia mitigación compensatoria ante la imposibilidad de parcheo [41]; y la formación IT/OT mediante CTF industriales [49] y testbeds [40] es una necesidad crítica.

Como trabajo futuro se priorizan dos líneas: (i) el desarrollo de **laboratorios OT** como el CiberLab de ICAI [10] que integren hardware industrial real, gemelos digitales adaptativos y honeypots, combinando validación representativa con captura de ataques reales; y (ii) la investigación en **explicabilidad, robustez adversarial y supervisión humana** de los sistemas de IA generativa que el AI Act exigirá en infraestructuras críticas. El desajuste entre la sofisticación de las amenazas y la limitada adopción de las defensas propuestas solo puede cerrarse mediante la colaboración efectiva entre academia, operadores industriales y reguladores sobre infraestructura de validación compartida.

AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por el proyecto eFORT (Horizon Europe, Grant Agreement No. 101075665) y por el programa predoctoral del Instituto de Investigación Tecnológica (IIT), Universidad Pontificia Comillas.

REFERENCIAS

- [1] European Union, “Directive (eu) 2022/2555 – nis 2 directive,” Official Journal of the European Union, 2022.

- [2] —, “Regulation (eu) 2024/2847 – cyber resilience act,” Official Journal of the European Union, 2024.
- [3] —, “Regulation (eu) 2024/1689 – artificial intelligence act,” Official Journal of the European Union, 2024.
- [4] S. Kapoor, S. Kumar, and H. Vardhan, “Cyber security of ot networks: A tutorial and survey,” arXiv, 2025.
- [5] F. R. V. Labs, “2025 threat roundup,” Forescout, Tech. Rep., 2025.
- [6] V. Diemunsch, L. Hirschi, and S. Kremer, “A comprehensive formal security analysis of opc ua,” *USENIX Security 2025*, 2025.
- [7] W. Jo and I. Ahmed, “Oops, it halted again: Exploiting plc memory for fun and profit in industrial control systems,” *USENIX WOOT ’25*, 2025.
- [8] N. Rodríguez-Pérez, J. Matanza, L. Sigrist, J. R. Torres, and G. López, “Madiot 3.0: Assessment of attacks to distributed energy resources and demand in a power system,” *IEEE Open Access Journal of Power and Energy*, vol. 12, pp. 552–563, 2025.
- [9] A. Bajwa, A. A. R. Tonoy, S. Rana, and I. Ahmed, “Cybersecurity in industrial control systems: A systematic literature review on ai-based threat detection for scada and iot networks,” in *1st Global Research and Innovation Conference 2025*, 2025.
- [10] F. B.-G. Marandyn, N. R. Pérez, and G. L. López, “Design and implementation of an OT cybersecurity laboratory with multi-generation PLC architecture and Purdue model segmentation,” in *6th International Workshop on Cyber-Physical Security for Critical Infrastructures Protection (CPS4CIP), ESORICS 2025*, ser. Lecture Notes in Computer Science. Springer, 2025.
- [11] D. Inc., “8th annual year in review 2025 ot/ics cybersecurity report,” *Informe de Industria*, 2025.
- [12] M. Bhole, T. Sauter, and W. Kastner, “Enhancing industrial cybersecurity: Insights from analyzing threat groups and strategies in operational technology environments,” *IEEE Open Journal of the Industrial Electronics Society*, vol. 6, pp. 145–157, 2025.
- [13] M. ATT&CK, “Mitre att&ck for ics: T0831 - manipulation of control,” *MITRE Knowledge Base*, 2025.
- [14] ENISA, “Enisa threat landscape 2025,” European Union Agency for Cybersecurity, Tech. Rep., 2025.
- [15] Honeywell, “Cyber threat report 2025: Insights and actions to manage cyber-physical threat convergence,” Honeywell, Tech. Rep., 2025.
- [16] S. Soltan, P. Mittal, and H. V. Poor, “Blacklot: Iot botnet of high wattage devices can disrupt the power grid,” *USENIX Security 2018*, 2018.
- [17] E. López-Morales, U. Planta, C. Rubio-Medrano, A. Abbasi, and A. A. Cardenas, “Sok: Security of programmable logic controllers,” *USENIX Security 2024*, 2024.
- [18] S. G. Abbas, M. O. Ozmen, A. Alsaheel, A. Khan, Z. B. Celik, and D. Xu, “Sain: Improving ics attack detection sensitivity via state-aware invariants,” *USENIX Security 2024*, 2024.
- [19] E. Algul, F. Dogan, A. A. Ahmad, and O. Polat, “Scadanet: A novel dataset for scada cybersecurity and intrusion detection,” *Computer Networks*, vol. 278, p. 112087, 2026.
- [20] C. Villa, C. Doumanidis, H. Lamri, P. H. N. Rajput, and M. Maniatakos, “Icsquartz: Scan cycle-aware and vendor-agnostic fuzzing for industrial control systems,” in *NDSS Symposium 2025*, 2025.
- [21] M. Ike, K. Sadoski, R. Valme, B. Sahin, S. Zonouz, and W. Lee, “Your control host intrusion left some physical breadcrumbs: Physical evidence-guided post-mortem triage of scada attacks,” *ACM ASIA CCS ’25*, 2025.
- [22] W. Zhang, N. Dong, T. Choi, G. Bai, and R. K. L. Ko, “Intelligent data refinement and analysis of real-world cyber attacks on scada systems,” *ACM E-Energy ’25*, 2025.
- [23] N. d’Ambrosio, G. Capodagli, G. Perrone, and S. P. Romano, “Scass: Breaking into scada systems security,” *Computers & Security*, vol. 151, p. 104315, 2025.
- [24] X. Etchezarreta, I. Garitano, M. Iturbe, and U. Zurutuza, “On the use of minicps for conducting rigorous security experiments in software-defined industrial control systems,” *Wireless Networks*, vol. 30, no. 9, pp. 7377–7390, 2024.
- [25] K. A. C. II, H. Coleman, and D. Hamilton, “Development of a digital twin software for scada focused anomaly and intrusion detection systems research,” *ACM SIGSIM-PADS ’25*, 2025.
- [26] N. Ortiz, A. A. Cardenas, and A. Wool, “Scada world: An exploration of the diversity in power grid networks,” *Proc. ACM Meas. Anal. Comput. Syst.*, vol. 8, no. 1, pp. 1–26, 2024.
- [27] N. Yalçın, S. Çakır, and S. Ünalı, “Attack detection using artificial intelligence methods for scada security,” *IEEE Internet of Things Journal*, vol. 11, no. 24, pp. 39 550–39 559, 2024.
- [28] F. Mesadieu, D. Torre, and A. Chennamaneni, “Leveraging deep reinforcement learning technique for intrusion detection in scada infrastructure,” *IEEE Access*, vol. 12, pp. 63 381–63 399, 2024.
- [29] C. Fung, E. Zeng, and L. Bauer, “Adopting ai to protect industrial control systems: Assessing challenges and opportunities from the operators’ perspective,” *SOUPS 2025*, 2025.
- [30] A. M. Y. Koay, R. K. L. Ko, H. Hettema, and K. Radke, “Machine learning in industrial control system (ics) security: current landscape, opportunities and challenges,” *Journal of Intelligent Information Systems*, vol. 60, no. 2, pp. 377–405, 2023.
- [31] X. S. de Camara, J. L. Flores, C. Arellano, A. Urbieto, and U. Zurutuza, “Clustered federated learning architecture for network anomaly detection in large scale heterogeneous iot networks,” *Computers & Security*, vol. 131, p. 103299, 2023.
- [32] V. Mayoral-Vilches *et al.*, “Cybersecurity ai in ot: Insights from an ai top-10 ranker in the dragos of ctf 2025,” arXiv, 2025.
- [33] European Union, “Delegated regulation (eu) 2024/1366 – network code on cybersecurity for electricity,” Official Journal of the European Union, 2024.
- [34] K. Stouffer *et al.*, “Guide to operational technology (ot) security,” NIST Special Publication, Tech. Rep., 2023.
- [35] B. Al-Sada, A. Sadighian, and G. Oligeri, “Mitre att&ck: State of the art and way forward,” *ACM Computing Surveys*, vol. 57, no. 1, pp. 1–42, 2024.
- [36] M. Nilsson, “Aligning eu cybersecurity regulations with ics security standards: A systematic literature review,” Tesis de Maestría (University of Skövde), Tech. Rep., 2025.
- [37] C. Alcaraz, H. Guzman, and J. Lopez, “Adaptive digital twin: Protection, deception, and testing,” *Future Generation Computer Systems*, vol. 179, p. 108357, 2026, in press.
- [38] Y. Peng *et al.*, “Autolabel: Automated fine-grained log labeling for cyber attack dataset generation,” *USENIX Security 2025*, 2025.
- [39] A. Raj, S. Das, H. Vardhan, H. Neema, A. Chhokra, and D. Balasubramanian, “Autonomous cybersecurity testbed for operational technology networks,” *ACM DESTION ’25*, 2025.
- [40] T. P. Akinremi, J. K. Appiah, A. R. Asadi, O. Ibitoye, and S. Popoola, “Driving factors behind adopting virtual testbeds for ics cybersecurity education,” *ACM SIGCITE 2025*, 2025.
- [41] P. Huff, N. Gandu, and P. Novák, “I can’t patch my ot systems! a look at cisa’s kevc workarounds & mitigations for ot,” arXiv, 2025.
- [42] C. . H. Energy, “Ics advisory: Hitachi energy fox61x,” CISA ICS Advisory, Tech. Rep., 2026.
- [43] I. H. Meskini, C. Alcaraz, R. R. Castro, and J. Lopez, “Analysis of transferable adversarial evasion attack detection in iot and industrial ads,” *IEEE Open Journal of the Computer Society*, vol. 7, pp. 142–153, 2025.
- [44] A. Lara-Gutierrez, C. Fernandez-Gago, and J. A. Onieva, “A framework for drift detection and adaptation in ai-driven anomaly and threat detection systems,” *International Journal of Information Security*, vol. 24, no. 5, p. 199, 2025.
- [45] M.-A. Jibotean and O.-P. Stan, “Cybersecurity challenges and strategies in critical infrastructure systems: A comprehensive survey,” *2025 ICSTCC*, 2025.
- [46] A. Yusuf, S. Li, A. S. Kawatra, D. Li, E.-C. Chang, and Z. Liang, “From observations to insights: Constructing effective cyberattack provenance with provcon,” *WOSOC 2025*, 2025.
- [47] A. Arias, C. Arellano, A. Urbieto, and U. Zurutuza, “Leveraging digital twins and siem integration for incident response in ot environments,” *JNIC 2024*, 2024.
- [48] C. Alcaraz and J. Lopez, “Digital twin-assisted anomaly detection for industrial scenarios,” *International Journal of Critical Infrastructure Protection*, vol. 47, p. 100721, 2024.
- [49] S. Abaimov, J. Gardiner, E. Samanis, J. Williams, M. Samanis, F. Shahbi, and A. Rashid, “Capture the industrial flag: Lessons from hosting an ics cybersecurity exercise,” *ACM CPSS ’24*, 2024.
- [50] C. Alcaraz and J. Lopez, “Protecting digital twin networks for 6g-enabled industry 5.0 ecosystems,” *IEEE Network Magazine*, vol. 38, no. 3, pp. 302–308, 2023.
- [51] J. I. N. Vidal, “Distributed honeypots as a proactive cyber threat detection mechanism in connected vehicles,” Reporte Técnico Independiente, Tech. Rep., 2025.
- [52] M. H. Rais, M. Ahsan, and I. Ahmed, “Sok: 3d printer firmware attacks on fused filament fabrication,” *USENIX WOOT 2024*, 2024.
- [53] R. Roman, C. Alcaraz, J. Lopez, and K. Sakurai, “Current perspectives on securing critical infrastructures’ supply chains,” *IEEE Security & Privacy*, vol. 21, no. 1, pp. 46–56, 2023.
- [54] C. Fung, E. Zeng, and L. Bauer, “Attributions for ml-based ics anomaly detection: From theory to practice,” in *NDSS Symposium 2024*, 2024.

IA explicable (XAI) para la detección de ataques orientada a aplicaciones IoT rurales inteligentes

E. Fernández-Morales

Programa de Doctorado en Sistemas Inteligentes,
Escuela Internacional de Doctorado UNED (EIDUNED),
UNED, Madrid, Spain
e.fernandez@scc.uned.es

Ll. Tobarra, A. Robles-Gómez, R. Pastor-Vargas, R. Hernández

Dpto. de Sistemas de Comunicación y Control
E.T.S.I Informática, UNED, Madrid, Spain
{llanos,arobles, rpastor, roberto}@scc.uned.es

J. Sarripa

Instituto de Desenvolvimento de Novas Tecnologias,
UNINOVA, Lisbon, Portugal
jfss@uninova.pt

Resumen—Este trabajo evalúa la precisión y la viabilidad de despliegue de modelos de Inteligencia Artificial (IA) para detección de intrusiones en redes de Internet de las Cosas (Internet of Things, IoT) con recursos limitados, como son los escenarios basados en entornos rurales, conocidos como Smart Rural. Para ello se han entrenado cinco modelos (Árboles de Decisión, Random Forest, dos distintos modelos MLP y un modelo LSTM) utilizando el dataset NF-UQ-NIDS-v2 (más de 76 millones de registros/conversaciones NetFlow y 20 clases de ataques junto con tráfico benigno). En la comparación, además de las métricas de rendimiento de detección, también se ha medido el coste en términos de recursos computacionales por lote en dos contextos: equipos informáticos comunes y microcontroladores IoT. Se han aplicado los algoritmos de explicabilidad SHAP y LIME para analizar la importancia de las características seleccionadas y su impacto en las predicciones. Los resultados obtenidos muestran que los modelos clásicos logran el mejor equilibrio entre precisión y coste computacional, mientras que los modelos basados en redes neuronales requieren optimización adicional para utilizarse en el borde (edge).

Index Terms—Internet of Things, Detección de anomalías, Deep Learning, XAI, Eficiencia Computacional.

Tipo de contribución: Investigación ya publicada

I. INTRODUCCIÓN

Los entornos rurales inteligentes, conocidos como Smart Rural, persiguen digitalizar servicios mediante IoT y analítica de datos para mejorar sostenibilidad y calidad de vida en estas áreas. Sin embargo, su adopción está condicionada por limitaciones de conectividad, presupuesto y capacidad de cómputo en el borde, así como por requisitos de ciberseguridad y protección de datos. En este contexto, la detección de intrusiones automatizada basada en IA es fundamental. Y debe evaluarse no solo por su capacidad predictiva, sino también por su coste computacional y su explicabilidad para facilitar su operación en campo garantizando una rápida respuesta adecuada antes un incidente y una constante auditoria del estado de la infraestructura.

Este resumen extendido sintetiza los resultados previamente

publicados en la siguiente revista [1], donde se estudia el compromiso rendimiento/coste de cinco modelos de clasificación de tráfico (dos modelos clásicos y tres redes neuronales) sobre el dataset NF-UQ-NIDS-v2 [2]. El objetivo es aportar evidencia práctica para seleccionar modelos de IDS que sean a la vez precisos, eficientes e interpretables en infraestructuras rurales y de bajos recursos. Las principales contribuciones de este trabajo son: I) Evaluación de cinco modelos de Inteligencia Artificial (DT, RF, MLP-16x1, MLP-1024x2 y LSTM-32x3) sobre mas de 76 millones de registros NetFlow y 21 clases; II) medición conjunta de métricas de clasificación y métricas de ejecución (tiempo, memoria, CPU y energía estimada) en dos entornos diferenciados y III) medición conjunta de métricas de clasificación y métricas de ejecución (tiempo, memoria, CPU y energía estimada) en dos entornos diferenciados.

II. DISEÑO EXPERIMENTAL

El diseño experimental de este estudio se lleva a cabo utilizando el conjunto de datos NF-UQ-NIDS-v2 [2]. Con el objetivo de garantizar una evaluación rigurosa y reproducible, y gracias al gran volumen de registros del conjunto, los datos se dividen en tres subconjuntos disjuntos siguiendo una partición 50/25/25 para entrenamiento, validación y evaluación, respectivamente. Esta estrategia permite ajustar los hiperparámetros de los modelos sobre el conjunto de validación sin comprometer la imparcialidad del conjunto de prueba, reservado exclusivamente para la evaluación final del rendimiento.

En cuanto a los modelos considerados, como baselines tradicionales se emplean Decision Tree (DT) y Random Forest (RF), seleccionados por su amplia adopción en la literatura y su equilibrio entre interpretabilidad y rendimiento. En paralelo, se analizan tres arquitecturas neuronales con distinta complejidad y capacidad de representación: una red recurrente LSTM con tres capas de 32 unidades cada una (LSTM-32x3), un perceptrón multicapa compacto con una sola capa oculta

de 16 neuronas (MLP-16x1) y un perceptrón multicapa de mayor capacidad con dos capas ocultas de 1024 neuronas cada una (MLP-1024x2). Esta selección permite comparar modelos ligeros frente a arquitecturas más profundas y expresivas, evaluando el compromiso entre precisión y coste computacional.

La evaluación experimental se realiza en dos plataformas con capacidades claramente diferenciadas, con el fin de analizar la viabilidad de despliegue en entornos heterogéneos. Por un lado, se emplea un entorno de alto rendimiento como referencia de desempeño. Por otro, se utiliza un dispositivo de bajo consumo y recursos limitados, concretamente una Raspberry Pi 4 con 8 GB de memoria RAM, representativa de escenarios de edge computing. La inferencia se evalúa procesando lotes de 1024 flujos de red Netflow, y se reportan tanto métricas clásicas de clasificación (accuracy, precisión, recall y F1-score) como métricas relacionadas con el consumo de recursos. Entre estas últimas se incluyen el tiempo de inferencia por lote, el uso de memoria, la utilización de CPU y una estimación de la energía consumida por la CPU durante el procesamiento de cada lote. Este análisis integral permite caracterizar no solo la efectividad predictiva de los modelos, sino también su eficiencia operativa en distintos contextos de despliegue.

Finalmente, se incorpora un análisis de explicabilidad con el objetivo de interpretar el comportamiento de los modelos y validar la coherencia de sus decisiones. Para ello se emplean dos técnicas complementarias: SHAP [3], orientada a la atribución global de importancia de variables, y LIME [4], centrada en la generación de explicaciones locales para instancias individuales. Los resultados obtenidos muestran una notable consistencia entre modelos y métodos de explicación, identificando de forma recurrente como variables más influyentes las características `L7_PROTO`, `OUT_PKTS`, `TCP_FLAGS`, `LONGEST_FLOW_PKT` y `TCP_WIN_MAX_IN`. Esta convergencia refuerza la robustez de los hallazgos y aporta evidencia adicional sobre la relevancia de determinados atributos de nivel de flujo en la detección de comportamientos maliciosos.

III. RESULTADOS Y DISCUSIÓN

La Tabla I resume el rendimiento predictivo y el coste de inferencia en Raspberry Pi 4. RF obtiene los mejores resultados de clasificación (98.96 % en accuracy y F1-score), seguido de DT (98.84 %). Entre los modelos neuronales, LSTM-32x3 y MLP-1024x2 logran rendimientos cercanos (96.95 % y 96.45 % en F1-score), mientras que MLP-16x1 reduce la precisión (93.69 % F1) a cambio de un coste de inferencia bajo.

En cuanto a viabilidad edge, DT, RF y MLP-16x1 mantienen tiempos por lote inferiores a 20 ms, frente a 110 ms (MLP-1024x2) y 317 ms (LSTM-32x3). En conjunto, los resultados apoyan el uso de modelos clásicos para despliegues con restricciones, y sitúan a las redes neuronales como candidatas condicionadas a optimización.

IV. CONCLUSIONES

Los modelos clásicos, en particular RF y DT, ofrecen el mejor equilibrio entre precisión y coste de inferencia en entorno de bajos recursos, por lo que son candidatos preferentes para despliegues Smart Rural. Los modelos de deep learning alcanzan rendimiento comparable en clasificación,

Tabla I
RESUMEN DE RENDIMIENTO Y COSTE EN RASPBERRY PI 4 (LOTES DE 1024 FLUJOS). LA ENERGÍA CORRESPONDE A CPU ESTIMADA POR LOTE.

Modelo	Acc.	F1	t_{inf} (ms)	E (J)
DT	98.84 %	98.84 %	4.4	0.045
RF	98.96 %	98.96 %	18.1	0.117
LSTM-32x3	96.90 %	96.95 %	316.9	1.899
MLP-16x1	93.66 %	93.69 %	5.7	0.036
MLP-1024x2	96.41 %	96.45 %	110.1	0.662




Figura 1. Tiempo medio de inferencia por lote en ambos entornos.

pero con mayor consumo, por lo que requieren optimizaciones antes de su uso práctico en edge. Como trabajo futuro, se plantea (i) optimizar y re-evaluar las redes neuronales en hardware restringido y (ii) validar estos modelos con tráfico representativo de despliegues rurales.

AGRADECIMIENTOS

Los autores desean agradecer el apoyo del Gobierno de España (a través del Instituto Nacional de Ciberseguridad de España, INCIBE), mediante el Proyecto Estratégico de Investigación “Analysis of mobile applications from the perspective of data protection: Cyber-protection and Cyber-risks of citizen information” y la Cátedra Internacional “Smart Rural IoT and Secured Environments”, en el marco del Plan de Recuperación, Transformación y Resiliencia financiado por la Unión Europea (NextGenerationEU/PRTR). Asimismo, los autores agradecen el apoyo del Consorcio del Centro Asociado de la UNED en Ponferrada, INTECCA, así como del grupo de investigación UNED CiberCSI y del grupo de innovación CiberGID.

REFERENCIAS

- [1] E. Fernández-Morales, L. Tobarra, A. Robles-Gómez, R. Pastor-Vargas, R. Hernández, and J. Sarraipa, “explicability ai (xai) for attack detection toward smart rural applications,” *Internet of Things*, vol. 34, p. 101804, 2025. [Online]. Available: <https://doi.org/10.1016/j.iot.2025.101804>
- [2] M. Sarhan, S. Layeghy, and M. Portmann, “Towards a standard feature set for network intrusion detection system datasets,” *Mobile Networks and Application*, vol. 27, 2022.
- [3] S. M. Lundberg and S.-I. Lee, “A unified approach to interpreting model predictions,” in *Advances in Neural Information Processing Systems 30*, I. Guyon, U. V. Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan, and R. Garnett, Eds. Curran Associates, Inc., 2017, pp. 4765–4774. [Online]. Available: <http://papers.nips.cc/paper/7062-a-unified-approach-to-interpreting-model-predictions.pdf>
- [4] M. T. Ribeiro, S. Singh, and C. Guestrin, ““why should i trust you?”: Explaining the predictions of any classifier,” 2016. [Online]. Available: <https://arxiv.org/abs/1602.04938>

Detección de anomalías temporales en accesos para sistemas UEBA

Vicente Mayor
Universidad de Sevilla
Sevilla, España
vmayor@us.es

Rafael Estepa
Universidad de Sevilla
Sevilla, España
rafaestepa@us.es

Jesús Esteban Díaz-Verdejo
Universidad de Granada
Granada, España
jedv@ugr.es

Antonio Estepa
Universidad de Sevilla
Sevilla, España
aestepa@us.es

Javier Muñoz-Calle
Universidad de Sevilla
Sevilla, España
fjmc@us.es

Isabel Román-Martínez
Universidad de Sevilla
Sevilla, España
irm@us.es

Resumen—Los insiders representan una amenaza crítica para las organizaciones porque pueden evadir controles tradicionales al operar con acceso legítimo. Los sistemas de Análisis de Comportamiento de Usuarios y Entidades (UEBA) permiten detectar desviaciones respecto al comportamiento normal, aunque su diseño práctico sigue siendo complejo en entornos reales. Este trabajo presenta un estudio sobre la capacidad de varias técnicas no supervisadas, basadas en particionado aleatorio, para detectar tiempos de acceso anómalos en un marco UEBA. En particular, se proponen y evalúan cinco modelos que aplican Isolation Forest (IF) y Extended Isolation Forest (EIF) sobre distintas representaciones geométricas del tiempo. Los resultados muestran que las variantes basadas en EIF y representaciones cíclicas superan a los enfoques lineales, alcanzando rendimientos superiores al 80 %, lo que orienta el diseño de futuros detectores temporales en sistemas UEBA.

Index Terms—amenazas insider, UEBA, IAM, detección de anomalías, ciberseguridad, modelado temporal

Tipo de contribución: Investigación en desarrollo

I. INTRODUCCIÓN

Las organizaciones despliegan cada vez más soluciones SIEM (Security Information Event Management) e IDS (Intrusion Detection System) [1], [2]. Aunque protegen la infraestructura frente a ataques externos, suelen ser insuficientes ante amenazas planteadas por usuarios maliciosos con acceso legítimo (insiders) [3], [4]. Estos usuarios pueden cometer fraude, sabotaje, espionaje o robo de propiedad intelectual y generar costes elevados [5], [2]. En este escenario, los sistemas UEBA modelan el perfil de normalidad de los usuarios y detectan desviaciones respecto a su comportamiento habitual, complementando así los controles basados en reglas [6], [7].

UEBA combina múltiples dominios de caracterización del comportamiento, como actividad temporal, recursos accedidos, localización de red, dispositivo o grupo de iguales [8]. Entre ellos, el momento de acceso al sistema es especialmente relevante, ya que la actividad de un empleado suele estar condicionada por su horario de trabajo. Así pues, la mayoría de sistemas UEBA incluyen este dominio. No obstante, el modelado temporal es complejo por la variabilidad humana, la evolución de los patrones, la dependencia contextual de lo anómalo y la naturaleza cíclica del tiempo. Además, la escasez de incidentes etiquetados dificulta la evaluación.

Este artículo se centra en comparar varios modelos de IA para detectar comportamientos anómalos en el dominio temporal. La investigación, aún en desarrollo, forma parte de un estudio más amplio sobre sistemas UEBA. A continuación se revisan antecedentes, se describen cinco detectores basados en IF/EIF y se presentan resultados experimentales que permiten seleccionar las variantes más prometedoras para una futura arquitectura UEBA.

II. ANTECEDENTES Y TRABAJOS RELACIONADOS

Los sistemas UEBA construyen perfiles de comportamiento combinando métodos de IA con reglas. De forma resumida, el flujo de trabajo comprende: (1) la ingestión de eventos de actividad; (2) la construcción de modelos de normalidad por usuario, entidad o grupo; (3) la evaluación operativa de nuevos eventos frente a dichos modelos; (4) la correlación de detectores para estimar riesgo; y (5) la generación de alertas explicables [9].

II-A. Técnicas y algoritmos para la detección de anomalías

La detección de anomalías puede abordarse mediante técnicas supervisadas o no supervisadas. En UEBA predominan las segundas porque las anomalías son escasas, las clases están muy desequilibradas y resulta difícil disponer de muestras para todos los comportamientos maliciosos posibles [10], [11]. Entre los no supervisados destacan enfoques estadísticos como HBOS [12] y Mahalanobis [13], así como técnicas basadas en distancia o densidad como kNN y LOF [14], [15]. También se emplean PCA y autoencoders [16], [17], aunque con mayor coste computacional y menor interpretabilidad.

En el ámbito UEBA, la familia *Isolation Forest* resulta especialmente atractiva por su eficiencia, escalabilidad y buen compromiso entre capacidad de detección y explicabilidad [18], [19]. Trabajos previos muestran, además, que enfoques más complejos no siempre mejoran de forma significativa a modelos más simples como EIF o PCA [10]. Por este motivo, este estudio se centra en IF y EIF.

II-B. Datasets disponibles

La utilidad de un sistema UEBA depende en gran medida de la disponibilidad de datasets representativos, y éstos siguen

siendo escasos. Para este trabajo se revisaron cuatro conjuntos públicos: Sci-Hub [20], CERT [21], GitHub [22] y CLUE-LDS [23]. La Tabla I resume sus principales características. Entre ellos, CLUE-LDS se consideró el más adecuado por su carácter corporativo y real, así como por incluir *timestamps*, actores, recursos, grupos, acciones y localización.

Tabla I: Resumen de datasets disponibles

Dataset	Corp.	Real	TS	Actor	Recurso	Loc.
Sci-Hub	×	✓	✓	✓	✓	✓
CERT	✓	×	✓	✓	✓	×
GitHub	×	✓	✓	✓	✓	×
CLUE-LDS	✓	✓	✓	✓	✓	✓

II-C. Sistemas UEBA en el dominio temporal

Los sistemas UEBA abarcan varios dominios y definen *features* para evaluar anomalías, desde conjuntos reducidos [24], [8] hasta espacios mucho más amplios [25], o incluso aplicar reducción de dimensionalidad [26], [27]. En general, combinan detectores de distinta naturaleza (p. ej., estadísticos, reconstrucción, etc.) que operan sobre las *features* de usuarios o grupos, cuyo modelo es actualizado en una ventana deslizante para afrontar la deriva temporal [28]. La literatura sugiere que no hay ningún método dominante y destacan la importancia de la geometría de las *features* y del dataset [16].

El dominio temporal es muy informativo, pero difícil de modelar por la variabilidad de los patrones de acceso y la naturaleza cíclica del tiempo; por ello destacan los enfoques que permiten modelar esa periodicidad, como *Isolation Forest* [29], [30], [31], [32] o los *autoencoders* [17], [33], [34].

III. MODELOS DE LA FAMILIA ISOLATION FOREST PARA LA DETECCIÓN DE ANOMALÍAS DEL DOMINIO TEMPORAL

Este estudio presupone que los usuarios corporativos exhiben un patrón temporal normal consistente y alineado con su horario laboral. Aunque es una simplificación, permite comparar entre sí las prestaciones de varios detectores. En un entorno de oficina típico, los registros de acceso muestran una concentración de eventos dentro del horario laboral, mientras que los accesos esporádicos fuera de ese periodo deberían marcarse como anómalos e indicativos de riesgo potencial. Si bien este comportamiento podría aproximarse mediante firmas, los sistemas UEBA permiten aprender automáticamente el horario de trabajo de usuarios y grupos.

Entre las técnicas posibles para este problema, se han seleccionado las basadas en *Isolation Forest* (IF) y *Extended Isolation Forest* (EIF), por ser ampliamente utilizadas en el dominio temporal de UEBA y por combinar explicabilidad, escalabilidad y complejidad computacional lineal [10], [18]. No obstante, para que estas técnicas resulten eficaces deben adaptarse a la periodicidad propia del tiempo y a la deriva gradual del patrón de accesos. Con ese objetivo se comparan cinco modelos basados en distintas geometrías del tiempo semanal, ilustradas en la Figura 1:

- **IF2D**: representación bidimensional de la hora de acceso frente al día de la semana. El tiempo se codifica en decimal —p.ej., 10:30 como 10.5— para mantener continuidad de escala y los ejes se normalizan en $[0, 1]$.

- **EIF2D**: mantiene las mismas *features*, pero sustituye IF por EIF para permitir fronteras de decisión oblicuas, más adecuadas en distribuciones complejas, lo que mejora su rendimiento, aunque con un mayor coste computacional.
- **EIF2DCircle**: introduce una proyección circular de la hora diaria para preservar la continuidad entre las 23:59 y las 00:00. De este modo, el modelo representa de forma natural la proximidad temporal al cruzar medianoche.
- **EIF2DMultiCircle**: extiende el modelo circular anterior separando cada día de la semana en círculos concéntricos. Los días se ordenan de lunes a domingo en radios crecientes, lo que facilita detectar anomalías durante los fines de semana, con menor actividad empresarial.
- **EIF3DCylinder**: representa cada día a una altura distinta sobre una geometría cilíndrica 3D, diseñado para superar la limitación específica del modelo anterior que tendría una mayor dificultad para encontrar una anomalía un lunes que un domingo debido al menor radio.

Todos los modelos comparten un único parámetro libre, la contaminación (C), usado para fijar el umbral de decisión asumiendo que una proporción de la muestra usada en el entrenamiento son *outliers*.

IV. RESULTADOS EXPERIMENTALES

Se desarrolló una implementación en Python para evaluar los modelos sobre CLUE-LDS [23], utilizando el año 2018 por ser el primer año completo disponible. Se seleccionaron 10 usuarios activos, persistentes y con comportamiento claramente humano, evitando perfiles similares a *bots*. Para evaluar la capacidad de detección se inyectaron 10 accesos anómalos consecutivos por usuario y semana, fuera del horario laboral, y se contabilizaron positivos y negativos para derivar las métricas clásicas (TP, FP, FN, TN), TPR, TNR y el rendimiento combinado, η (Ecuación 3). Dado que el dataset carece de etiquetas, se asumió que no contiene anomalías.

$$TPR = TP / (TP + FN) \quad (1)$$

$$TNR = TN / (TN + FP) \quad (2)$$

$$\eta = \sqrt{TPR \cdot TNR} \quad (3)$$

La Tabla II presenta los resultados obtenidos para cada valor de $C \in \{0.5, 1, 2, 5\}$, evaluando también el impacto de la ventana de entrenamiento S y de la frecuencia de reentrenamiento (R), ambas medidas en semanas, destacando los valores cuyo TNR supera el 98 %. A partir de estos resultados, se pueden extraer las siguientes observaciones principales.

Primero, EIF2D presenta un rendimiento superior al de IF2D: aunque éste puede ofrecer TNR algo mayor, su TPR es claramente inferior. Segundo, para todos los modelos, aumentar la contaminación incrementa los falsos positivos; las mejores configuraciones aparecen de forma sistemática con $C < 1\%$, especialmente en 0,5 %. Tercero, el tamaño de la ventana de entrenamiento influye de forma notable, y las mejores combinaciones se concentran en $S = 16$ o 20 semanas; de hecho, la mayoría de configuraciones con TNR superior al 98 % se obtiene precisamente con esas ventanas más largas. Cuarto, la frecuencia de reentrenamiento no afecta significativamente al rendimiento promedio: en $R = 1$ ofrece el mayor rendimiento global, aunque algunos modelos maximizan TPR con $R = 2$ sin penalizar de forma apreciable




Figura 1: Representación de IF2D/EIF2D, EIF2DCircle, EIF2DMultiCircle y EIF3DCylinder.

Tabla II: Rendimiento del modelo (η) para las distintas combinaciones de R , S y C .

Modelo	R S C	1				2				4			
		8	12	16	20	8	12	16	20	8	12	16	20
IF2D	0.5 %	0.509	0.535	0.531	0.531	0.499	0.489	0.492	0.549	0.494	0.492	0.478	0.511
	1 %	0.580	0.581	0.606	0.617	0.597	0.609	0.642	0.645	0.590	0.597	0.646	0.647
	2 %	0.676	0.717	0.730	0.743	0.689	0.735	0.725	0.695	0.687	0.708	0.747	0.724
	5 %	0.766	0.796	0.802	0.811	0.780	0.833	0.823	0.790	0.776	0.841	0.822	0.803
EIF2D	0.5 %	0.623	0.638	0.667	0.674	0.617	0.651	0.612	0.674	0.619	0.637	0.642	0.607
	1 %	0.742	0.741	0.760	0.763	0.730	0.755	0.777	0.781	0.759	0.765	0.799	0.759
	2 %	0.794	0.802	0.848	0.856	0.821	0.846	0.869	0.847	0.794	0.838	0.835	0.855
	5 %	0.752	0.757	0.802	0.772	0.735	0.832	0.786	0.771	0.761	0.790	0.774	0.777
EIF2DCircle	0.5 %	0.863	0.859	0.885	0.869	0.868	0.875	0.873	0.878	0.852	0.865	0.882	0.873
	1 %	0.847	0.866	0.870	0.882	0.856	0.889	0.877	0.874	0.867	0.869	0.874	0.886
	2 %	0.836	0.852	0.862	0.873	0.837	0.866	0.856	0.862	0.840	0.870	0.843	0.850
	5 %	0.792	0.814	0.826	0.812	0.803	0.844	0.807	0.816	0.791	0.833	0.811	0.810
EIF2DMultiCircle	0.5 %	0.757	0.744	0.756	0.757	0.771	0.760	0.773	0.760	0.744	0.722	0.757	0.769
	1 %	0.816	0.795	0.797	0.828	0.817	0.846	0.810	0.834	0.818	0.836	0.836	0.827
	2 %	0.808	0.810	0.872	0.866	0.833	0.865	0.847	0.846	0.834	0.854	0.843	0.866
	5 %	0.765	0.800	0.778	0.798	0.766	0.840	0.786	0.795	0.769	0.841	0.780	0.795
EIF3DCylinder	0.5 %	0.831	0.837	0.868	0.861	0.836	0.855	0.857	0.869	0.835	0.851	0.866	0.844
	1 %	0.878	0.833	0.887	0.894	0.853	0.875	0.887	0.888	0.854	0.864	0.891	0.888
	2 %	0.818	0.842	0.879	0.908	0.845	0.876	0.896	0.898	0.854	0.874	0.882	0.887
	5 %	0.758	0.804	0.785	0.834	0.788	0.836	0.768	0.803	0.783	0.840	0.783	0.830

*Como referencia, los valores con TNR mayor que 98 % han sido señalados en negrita.

la tasa de falsos positivos. Quinto, bajo la parametrización óptima, EIF2DCircle presenta el mejor rendimiento, seguido de EIF3DCylinder; EIF2DMultiCircle muestra un rendimiento medio algo inferior, pero con la menor tasa de falsos positivos.

En consecuencia, los modelos con mejor comportamiento son EIF3DCylinder, EIF2DCircle y EIF2DMultiCircle bajo contaminación del 0.5 %, reentrenamiento semanal y ventana de entrenamiento de 16 semanas. La Figura 2 muestra la evolución mensual del rendimiento y de la capacidad de detección en esta configuración. EIF2DCircle y EIF3DCylinder mantienen valores de η superiores al 80 % durante todo el periodo analizado, mientras que EIF2DMultiCircle se sitúa en torno al 75–80 %. En términos de TPR, los dos mejores modelos detectan entre el 75 % y el 80 % de los ataques, mientras que EIF2DMultiCircle ronda el 60 % y los modelos lineales no alcanzan el 50 %.

La degradación observada en octubre, noviembre y diciembre puede explicarse por efectos estacionales: vacaciones, plazos de proyectos y festivos modifican el comportamiento basal y reducen la representatividad de las ventanas de entrenamiento previas. Una limitación del estudio es la ausencia de anomalías reales etiquetadas, lo que obliga a recurrir a la inyección sintética de eventos.

V. CONCLUSIONES Y TRABAJOS FUTUROS

Entre los modelos evaluados, EIF2DCircle, EIF2DMultiCircle y EIF3DCylinder demostraron el mejor

rendimiento global. La siguiente fase de esta investigación se centrará en el diseño de un ensamblado por votación (*voting ensemble*) que agregue estas distintas perspectivas geométricas, con el objetivo de reducir la tasa de falsos positivos sin comprometer significativamente la capacidad de detección. Asimismo, se abordará la validación sobre datasets adicionales para evaluar la robustez de los modelos en contextos heterogéneos.

Por último, se ampliará el alcance del marco UEBA con detectores multidominio, como localización, velocidad de desplazamiento, entre otros. El objetivo final es evolucionar hacia un sistema UEBA integral capaz de correlacionar múltiples dimensiones del comportamiento de usuarios y entidades para mejorar la precisión y reducir el riesgo operativo.

AGRADECIMIENTOS

Esta publicación es parte del proyecto de I+D+i PID2024-155581OB-C21, financiado/a por MICIU/AEI/10.13039/501100011033/ FEDER/UE.

REFERENCIAS

- [1] N. Saxena, E. Hayes, E. Bertino, P. Ojo, K. K. R. Choo, and P. Burnap, "Impact and key challenges of insider threats on organizations and critical businesses", en *Electronics*, vol. 9, no. 9, p. 1460, 2020, doi: 10.3390/electronics9091460
- [2] Cybersecurity Insiders, "2024 Insider Threat Report – Gurukul", Available: <https://www.cybersecurity-insiders.com/portfolio/2024-insider-threat-report-gurukul/>. [Accessed: Feb. 23, 2026].




Figura 2: Resultados con la mejor configuración ($R = 1$, $S = 16$, $C = 0,5\%$): η y TPR.

- [3] F. L. Greitzer and R. Hohimer, "Modeling Human Behavior to Anticipate Insider Attacks", en *Journal of Strategic Security*, vol. 4, no. 2, pp. 25–48, 2014, doi: 10.5038/1944-0472.4.2.2
- [4] Verizon, "2024 Data Breach Investigations Report," 2024. [Online]. Available: <https://www.verizon.com/business/resources/reports/dbir/>
- [5] CERT National Insider Threat Center, "Common Sense Guide to Mitigating Insider Threats, Sixth Edition", CMU/SEI-2018-TR-010, Dec. 2018. Available: <http://www.sei.cmu.edu>
- [6] Raut, M., Dhavale, S., Singh, A., and Mehra, A., "Insider threat detection using deep learning: A review", en *2020 3rd International Conference on Intelligent Sustainable Systems (ICISS)*, IEEE, 2020, doi: 10.1109/ICISS49785.2020.9315932
- [7] Datta, J., Dasgupta, R., Dasgupta, S., and Reddy, K. R., "Real-time threat detection in ueba using unsupervised learning algorithms", en *2021 5th International Conference on Electronics, Materials Engineering & Nano-Technology (IEMENTech)*, IEEE, 2021, doi: 10.1109/IEMENTech53263.2021.9614848
- [8] M. Shashanka, M.-Y. Shen, and J. Wang, "User and entity behavior analytics for enterprise security", en *2016 IEEE International Conference on Big Data (Big Data)*, IEEE, 2016, doi: 10.1109/BigData.2016.7840805
- [9] P. A. Savenkov and A. N. Ivutin, "Methods of machine learning in system abnormal behavior detection", en *Advances in Swarm Intelligence: 11th International Conference, ICSI 2020, Belgrade, Serbia, July 14–20, 2020, Proceedings 11*, Springer International Publishing, 2020, doi: 10.1007/978-3-030-53956-6_45
- [10] N. A. M. L. Cardoso, "User behavior analytics in the contact center: Insider threat assessment and fraud detection", Master's thesis, University of Coimbra, 2021.
- [11] A. Dal Pozzolo, "Adaptive machine learning for credit card fraud detection.", Ph.D. dissertation, Université libre de Bruxelles, 2015.
- [12] M. Goldstein and A. Dengel, "Histogram-based outlier score (HBOS): A fast unsupervised anomaly detection algorithm", en *KI-2012: Poster and Demo Track*, vol. 1, pp. 59–63, 2012.
- [13] R. De Maesschalck, D. Jouan-Rimbaud and D. L. Massart, "The Mahalanobis distance", en *Chemometrics and Intelligent Laboratory Systems*, vol. 50, n. 1, pp. 1–18, 2000.
- [14] M. Goldstein and S. Uchida, "A comparative evaluation of unsupervised anomaly detection algorithms for multivariate data", en *PLoS ONE*, vol. 11, n. 4, 2016.
- [15] M. M. Breunig, H.-P. Kriegel, R. T. Ng and J. Sander, "LOF: Identifying density-based local outliers", en *Proceedings of the 2000 ACM SIGMOD International Conference on Management of Data*, pp. 93–104, 2000.
- [16] Xiaotong Chen, Linfu Sun, He Wang, Tong Gu, Zhiqiang Jiang, "A-UEBA: An Anomaly Heterogeneity Learning Framework Based on Multi-Endpoint User and Entity Behavior Analysis", en *EILM '25: Proceedings of the 2025 International Conference on Embodied Intelligence and Large Models*, Diciembre, 2025.
- [17] Shanmugavelan Ramakrishnan, "Enhancing Identity and Access Management Systems with Behavioral Analytics: A Novel Approach to Detecting Anomalous Activities", en *Journal of Engineering and Applied Sciences Technology*, 2022.
- [18] F. T. Liu, K. M. Ting and Z.-H. Zhou, "Isolation Forest", en *2008 Eighth IEEE International Conference on Data Mining*, pp. 413–422, 2008.
- [19] S. Hariri, M. Carrasco Kind and R. J. Brunner, "Extended Isolation Forest", en *IEEE Transactions on Knowledge and Data Engineering*, vol. 33, n. 4, pp. 1479–1489, 2021.
- [20] A. Elbakyan, "Sci-Hub download log of 2017", en *Zenodo*, 2018. DOI: 10.5281/zenodo.1158301.
- [21] J. Glasser and B. Lindauer, "Bridging the gap: A pragmatic approach to generating insider threat data", en *2013 IEEE Security and Privacy Workshops*, pp. 98–104, 2013.
- [22] N. Chidambaram, A. Decan and T. Mens, "A dataset of bot and human activities in GitHub", en *2023 IEEE/ACM 20th International Conference on Mining Software Repositories (MSR)*, pp. 618–622, 2023.
- [23] M. Landauer, F. Skopik, G. Höld and M. Wurzenberger, "A user and entity behavior analytics log data set for anomaly detection in cloud computing", en *2022 IEEE International Conference on Big Data (Big Data)*, 2022.
- [24] R. Yousef and M. Jazzar, "Measuring the effectiveness of user and entity behavior analytics for the prevention of insider threats", en *J. Xi'an Univ. Arch. & Technol.*, vol. 8, pp. 175–181, 2021.
- [25] P. A. Legg, et al., "Automated insider threat detection system using user and role-based profile assessment", *IEEE Systems Journal*, vol. 11, no. 2, pp. 503–512, 2015.
- [26] T. Rashid, I. Agraftotis, and J. R. C. Nurse, "A new take on detecting insider threats: exploring the use of hidden markov models", en *Proceedings of the 8th ACM CCS International workshop on managing insider security threats*, 2016.
- [27] P. A. Legg, et al., "Caught in the act of an insider attack: detection and assessment of insider threat", en *2015 IEEE International Symposium on Technologies for Homeland Security (HST)*, IEEE, 2015.
- [28] Aljumaily, M., Abd, H., and Majeed, E., "Enhancing User and Entity Behavior Analytics in SIEM Systems Using AI-Powered Anomaly Detection: A Data-Driven Simulation Approach", en *International Journal of Mechatronics, Robotics, and Artificial Intelligence*, 1(2), 82–93, 2025, doi: 10.33971/ijmrai.1.2.11
- [29] Jing Liu, Jingci Zhang, Changcun Du, Dianxin Wang, "MUEBA: A Multi-model System for Insider Threat Detection", en *International Conference on Machine Learning for Cyber Security*, 2022, doi: 10.1007/978-3-031-20096-0_23
- [30] Adam Jordan, Yong Chen, "User and Entity Behavior Analytics (UEBA) Enhanced Security Anomaly Detection", en *2025 IEEE Secure Development Conference (SecDev)*, 2025.
- [31] Shantabhushana, B. M., Sudarsanan, D., Mithun, B. M., Sandeep Kumar, S., and Rakesh, V. S., "Profiling User Behavior to Identify Insider Threats", en *ITM Web of Conferences*, 2025, doi: 10.1051/itm-conf/20257901012
- [32] Hassan, A., Rauf, A., Shafqat, N., Latif, R., and Khan, H., "ZenGuard a machine learning based zero trust framework for context aware threat mitigation using SIEM SOAR and UEBA", en *Scientific Reports*, 2025, doi: 10.1038/s41598-025-20998-4
- [33] Yuan, L. P., Choo, E., Yu, T., Khalil, I., and Zhu, S., "Time-Window Based Group-Behavior Supported Method for Accurate Detection of Anomalous Users", en *2021 51st Annual IEEE/IFIP International Conference on Dependable Systems and Networks (DSN)*, 2021, doi: 10.1109/DSN48987.2021.00038
- [34] Sree Rajya Lakshmi Popury, "Behavioral Authentication with Real-Time Anomaly Detection in Enterprise Logins", en *International Journal of Engineering And Computer Science*, 2025, doi: 10.18535/ijecs.v14i08.5207

Sesión de Investigación 4 - Escenarios y plataformas II

Quantitative Cyber-Physical Risk Assessment using Co-Simulation

Mohammadhossein Homaei*, Inda Kreso[†], Óscar Mogollón Gutiérrez*, Alberto López Trigo*, Andrés Caro*

* Grupo de Ingeniería de Medios, Universidad de Extremadura
Cáceres, Spain

mhomaein@alumnos.unex.es, {oscarimg, albertolt, andresc}@unex.es

[†] Dept. Criminal Justice, Criminology and Security Studies

University of Sarajevo

Sarajevo, Bosnia and Herzegovina

indakreso@fkn.unsa.ba

Abstract—Automated risk assessment in Cyber-Physical Systems (CPS) mainly relies on IT-centric frameworks like CVSS or purely data-driven anomaly detectors. These approaches are state-blind; they measure network exploitability or statistical rarity without capturing the real kinematic or thermodynamic impact of attacks. This gap causes alert fatigue and triage failures in Security Operations Centers (SOCs). To overcome this, we propose Cyber-Physical Impact Quantification (CPIQ), a real-time framework using co-simulation. CPIQ combines network alerts with an Extended Kalman Filter (EKF) and a physics-based Digital Twin to simulate physical states under attack. By tracking safety margin violations over a predictive horizon, it produces dynamic, consequence-aware risk scores. Tested on 18 cyber-physical attacks on the SWaT testbed, CPIQ achieves 0.94 Spearman correlation with expert judgment, outperforms static, topological, and ML baselines, shows 0% critical misses, and fully suppresses IT-only false positives with 2.13 s average latency, balancing precision and SOC timing constraints.

Index Terms—Cyber-Physical Systems, Dynamic Risk Assessment, Digital Twin, Co-Simulation, Security Operations Center

leading to distorted impact estimation.

To address this gap, we propose a real-time cyber-physical risk assessment framework that links intrusion alerts with physics-based consequence prediction. By simulating process dynamics through a calibrated DT, the framework quantifies actual safety violations rather than isolated exploitability. Validation on 18 SWaT attack scenarios demonstrates expert-level risk agreement with sub-second latency suitable for operational security triage. [8]

The remainder of this paper is organized as follows. Section II reviews existing risk assessment approaches and highlights the gap between static scoring and physics-aware impact analysis. Section III defines the state-blindness problem and introduces a motivating attack scenario. Section IV describes the CPIQ architecture, including the DT model and impact scoring mechanism. Section V reports experimental validation on the SWaT testbed against five baseline methods. Section VI discusses robustness and deployment aspects, and Section VII concludes the paper with future directions.

I. INTRODUCTION

The integration of Operational Technology (OT) and Information Technology (IT) has transformed modern Industrial Control Systems (ICS). While this connectivity improves efficiency in Cyber-Physical Systems (CPS), it removes the traditional air gap and introduces significant security exposure. Technologies such as digital twins (DTs) are increasingly adopted to monitor and virtualize these environments [1], [2]. However, the threat landscape remains asymmetric: attackers can exploit common network weaknesses to influence thermodynamic or kinematic processes. As CPS becomes more integrated with smart infrastructure, stronger security mechanisms beyond the network layer are required [3].

Despite the inherently physical nature of ICS, automated risk evaluation still relies largely on IT-centric frameworks such as CVSS and conventional Quantitative Risk Assessment (QRA). Recent research highlights that these models are static, state-unaware, and unable to capture dynamic uncertainty or cyber-physical interdependency [4], [5]. They emphasize software exploitability and fixed asset criticality, while ignoring real-time process conditions and nonlinear accident evolution [6], [7]. For instance, an actuator compromise may receive the same static score whether a tank is empty or near overflow,

II. RELATED WORKS

Cyber-physical risk assessment uses static vulnerability scoring and topological attack modelling, data-driven anomaly detection, and physics-based formal methodologies [9]. Each model addresses certain threat quantification features, but none achieves real-time practicality, state-aware consequence prediction, and broad industrial process applicability.

A. Static and Topological Risk Assessment

Traditional industrial risk assessment mainly adapts IT-based frameworks. The Common Vulnerability Scoring System (CVSS) [10] standardizes exploitability scoring, but its environmental metrics are static and state-blind. To model network dynamics, researchers use Dynamic Bayesian Attack Graphs (DBAG) [11] and hybrid knowledge-based systems [12] to estimate probabilistic threat propagation. Although these topological methods identify intrusion paths and support response planning, they ignore continuous physical dynamics. As a result, their probability scores do not directly reflect actual physical damage (e.g., overflow volume or equipment degradation), creating a gap in consequence quantification.

B. Data-Driven Anomaly Detection

Recent research proposes many data-driven anomaly detection models for multivariate time-series data, often tested on SWaT [13]. Advanced models like TIMESNet [14], TranAD [15], and SFAFormer [16] show high accuracy in detecting statistical deviations from normal behavior. However, there is a semantic gap between anomaly detection and physical consequence estimation. Deep models measure reconstruction error in latent space, but they do not understand mass balance or physical laws. As a result, events like IT reconnaissance scans can receive high anomaly scores even with no real physical risk, increasing false positives during triage.

C. Physics-Based and Formal Security Analysis

To address the limits of topological and data-driven methods, researchers study physics-aware approaches. Formal methods like reachability analysis [17] compute all possible system states under attack and give strong safety guarantees. However, in non-linear industrial systems, state-space grows fast, so computation becomes too expensive for real-time SOC triage. Co-simulation and cyber-physical coordination methods [18] try to connect network activity with physical models. Still, many existing solutions focus on specific applications (e.g., VPP voltage support) and are not general frameworks for consequence quantification in arbitrary ODE-based industrial systems.

Table I
COMPARATIVE ANALYSIS OF RISK ASSESSMENT APPROACHES FOR
REAL-TIME CPS SECURITY

Method	Real-time (<60s)	Physics- aware	State- dependent	Quantitative Risk Score
CVSS v3.1 [10]	✓	×	×	Categorical
DBAG [11]	✓	×	Partial	Probability
TranAD [15]	✓	×	×	Anomaly score
TIMESNet [14]	✓	×	×	Anomaly score
Reachability [17]	× (145s)	✓	✓	Binary
SDN-Based [18]	✓	✓	✓	Domain-specific
CPIQ (Ours)	✓ (2.1s)	✓	✓	0–10 continuous

D. Research Gaps and Research Questions

Table I shows a main trade-off in previous work. Data-driven models like TranAD and TIMESNet are fast but ignore physical impact. Formal methods such as Reachability Analysis give safety guarantees, but they are computationally heavy. Hybrid works [18] link SDN with physics-aware control, yet they are domain-specific and do not provide a general framework for safety violation quantification.

To address this gap, we ask: *How can ODE-based system physics be combined with real-time state estimation to quantify dynamic physical risk of cyber alerts under strict near real-time SOC latency constraints?*

III. PROBLEM STATEMENT

Industrial standards such as ISA/IEC 62443 and MITRE ATT&CK for ICS give strong guidance for threat modeling and governance. However, in practice, automated risk scoring still depends on IT-based frameworks like CVSS. These approaches focus on *exploitability* (e.g., attack vector or privileges) and do not measure real *physical consequences*. In industrial environments, this can cause wrong prioritization.

For example, a high CVSS score (9.0) on a redundant historian may have low operational impact, while a medium score (5.3) on a safety actuator can lead to equipment damage, production stop, or safety hazards.

A. Motivating Example: SWaT Attack Scenario 14

We analyze Attack #14 from the SWaT testbed, where the attacker spoofed level sensor LIT101 and caused tank overflow. This case shows limitation of IT-based scoring.

Attack execution: The attacker injected false value to LIT101, reporting 500mm while real level was 750mm (94% full). The PLC interpreted this as low level and turned on pump P101. After 5.2 minutes ($t = 312s$), the tank overflowed, which damaged equipment and required emergency shutdown.

Risk assessment gap:

- CVSS Environmental score: 7.1/10
- Real physical outcome: Equipment damage, 6-hour downtime
- Actual operational risk: Critical (9.5/10)

Important point is that CVSS gives score 7.1 whether tank is empty or 94% full. *Static scoring cannot reflect state-dependent physical impact.*

B. Problem Formalization

For a cyber alert a_i in an OT system, traditional scoring computes:

$$R_{static}(a_i) = f(\text{Exploitability, CIA Impact}) \quad (1)$$

where values come from CVSS metrics. This model has three main weaknesses in cyber-physical systems:

(1) **State-blindness.** Risk is calculated without considering current physical state $x(t)$. But consequence depends on operation condition, e.g., stopping a pump when tank is empty or almost full.

(2) **Dynamics-blindness.** Static score does not estimate how process evolves after compromise. Risk evaluation needs prediction of state $x(t + \tau)$ over horizon τ .

(3) **Consequence abstraction.** CVSS uses qualitative levels (Low/Medium/High) which are not directly mapped to quantitative effects like damage, safety violation, or production loss.

Therefore, we define a mapping:

$$\Phi : (a_i, x_{current}) \rightarrow \text{Physical Risk Score} \quad (2)$$

which combines cyber exploitability and physics-based consequence estimation.

Without mapping Φ , industrial SOC face serious problems:

- 1) **Alert Prioritization Problem:** 50–200 daily alerts must be checked manually, without systematic way to detect physically critical threats
- 2) **Wrong Resource Allocation:** Teams spend time on high-CVSS alerts for non-critical assets, while moderate attacks on safety devices may be ignored
- 3) **Late Mitigation:** Without impact prediction, operators react only after physical damage happens, often by emergency shutdown




Figure 1. CPIQ framework architecture showing the four-stage pipeline from network alert parsing to physics-based risk score generation.

C. Research Objective

We introduce *Cyber-Physical Impact Quantification* (CPIQ), a framework that applies physics-based simulation to estimate physical effect of cyber attacks in near real-time. CPIQ realizes mapping Φ by:

- 1) Converting network alerts into physical attack actions (e.g., Modbus write to LIT101)
- 2) Simulating process response using calibrated DT
- 3) Measuring safety violation over prediction horizon
- 4) Producing context-aware risk score based on predicted physical impact

IV. PROPOSED METHODOLOGY: CPIQ

To overcome the limitations discussed in Section III, we propose the *Cyber-Physical Impact Quantification* (CPIQ) framework. Unlike static scoring methods or attack graphs, CPIQ uses a calibrated DT of the industrial process to run physics-based forward simulations and predict physical damage over time.

A. System Architecture

CPIQ consists of four main components (Figure 1):

(1) Protocol Analyzer: Extracts attack parameters from OT network traffic. For Modbus traffic, this includes register addresses, function codes, and written values. We use Zeek ICS analyzers [19] for packet parsing.

(2) Cyber-to-Physical Translator: Maps network-level indicators to physical variables using the SCADA tag database. Example mappings for SWaT:

- Modbus address 30001 $\rightarrow$ LIT101 (Tank level sensor, mm)
- Modbus address 30011 $\rightarrow$ P101 (Inlet pump, ON/OFF)

(3) DT Simulator: A physics-based model of the water treatment process that predicts system evolution under attack. The model encodes:

- Mass balance: $\frac{dV}{dt} = Q_{in} - Q_{out}$
- Flow dynamics: $Q = C_d A \sqrt{2gh}$ (Bernoulli equation)
- Actuator responses: pump curves, valve characteristics

We use `scipy.integrate.solve_ivp` with RK45 integration.

(4) Risk Scorer: Quantifies safety violations from the simulation trajectory and generates the final risk score.

State estimation: To reduce sensor noise and short spikes in SWaT data, we use an Extended Kalman Filter (EKF) for real-time state estimation. The EKF generates the initial state vector $\hat{x}(0)$ for the DT, so the simulation starts from a clean physical baseline.

B. DT Model

We present the physics model for SWaT Stage P1 (water intake) as a representative example. The stage contains:

- Tank T101 (1000L capacity, 0-1000mm level range)
- Inlet pump P101 (2.5 L/s rated flow)
- Motorized valve MV101 (variable 0-100% opening)

The model tracks tank volume $V(t)$ based on mass conservation:

$$\frac{dV}{dt} = Q_{in}(t) - Q_{out}(t) \quad (3)$$

Inflow is determined by pump status:

$$Q_{in} = P_{101} \cdot Q_{max} \cdot \eta_{pump} \quad (4)$$

where $P_{101} \in \{0, 1\}$ is the pump state, $Q_{max} = 2.5 \times 10^{-3} \text{ m}^3/\text{s}$ is the rated capacity, and $\eta_{pump} = 0.92$ is the pump efficiency.

Outflow follows Bernoulli's equation for gravity-driven discharge:

$$Q_{out} = C_d \cdot A_{valve} \cdot MV_{101} \cdot \sqrt{2g \left(\frac{V}{A_{tank}} \right)} \quad (5)$$

where $C_d = 0.61$ is the discharge coefficient, $A_{valve} = 0.0025 \text{ m}^2$ is the valve cross-sectional area, $MV_{101} \in [0, 1]$ is the motorized valve position, $g = 9.81 \text{ m/s}^2$ is gravitational acceleration, and $A_{tank} = 1.0 \text{ m}^2$ is the tank base area.

To ensure dimensional homogeneity, the state variable $V(t)$ is strictly maintained in cubic meters (m^3) during ODE integration, where 1000L capacity corresponds to $V_{max} = 1.0 \text{ m}^3$.

Safety thresholds:

- Low alarm: 250mm, High alarm: 800mm, Overflow: 1000mm

Model calibration: The DT requires precise parameterization to match empirical plant behavior. The 7-day normal operation dataset was strictly partitioned. Parameters governing non-linear dynamics—specifically the gravity discharge

coefficients (C_d), pump efficiencies (η_{pump}), and empirically observed valve stroke delays (τ_{valve})—were estimated utilizing Bayesian optimization. The objective function minimized the L2 norm between the simulated trajectories and actual EKF-denoised sensor readings over the first 5 days. The remaining 2 days were held out as a strict, unseen test set to prevent overfitting, yielding a hold-out Validation MAE of 12.3mm (approximately 1.2% of the operational range).

C. Attack Modeling

We simulate three attack types for alerts mapped to physical tag ($tag, value_{mal}$).

Sensor spoofing: The attacker injects false readings $y_{measured} = y_{true} + \delta_{attack}$ while the physical state stays unchanged. The PLC then reacts to corrupted feedback. Example: Attack #14 spoofs LIT101 with $\delta = -250\text{mm}$.

Actuator hijacking: The attacker overrides controller outputs and forces actuators to malicious states. Example: Attack #3 forces a pump ON while closing the outlet valve.

Setpoint manipulation: The attacker changes controller setpoints to push the system toward unsafe conditions. Example: raising tank level setpoint to 950mm (near overflow).

In all cases, attacks start at $t = 0$ and are simulated forward for 30 minutes using the DT.

D. Threat Model

We assume a Dolev-Yao style adversary who has breached the OT network perimeter and can inject commands or spoof sensor data. The attacker is assumed to have full knowledge of system state $x(t)$ and can launch state-aware attacks. However, SWaT dataset attacks are mostly opportunistic, and CPIQ still estimates worst-case physical consequences.

Out of Scope: The CPIQ framework is assumed to run in an isolated SOC segment. Stealthy attacks below EKF noise thresholds may exist, but physical constraints should eventually reveal abnormal system behavior.

E. Physics-Based Impact Quantification

We quantify physical impact through safety violations over the 30-minute simulation horizon. For each safety-critical variable j , we define both lower ($x_{j,safe}^L, x_{j,crit}^L$) and upper ($x_{j,safe}^U, x_{j,crit}^U$) bounds. The violation penalty is formulated as a piecewise function to capture deviations in either direction:

$$\psi_j(t) = \begin{cases} 0 & \text{if } x_{j,safe}^L \leq x_j(t) \leq x_{j,safe}^U \\ \left(\frac{x_{j,safe}^L - x_j(t)}{x_{j,safe}^L - x_{j,crit}^L} \right)^2 & \text{if } x_{j,crit}^L < x_j(t) < x_{j,safe}^L \\ \left(\frac{x_j(t) - x_{j,safe}^U}{x_{j,crit}^U - x_{j,safe}^U} \right)^2 & \text{if } x_{j,safe}^U < x_j(t) < x_{j,crit}^U \\ 5.0 & \text{otherwise (critical violation)} \end{cases} \quad (6)$$

The quadratic penalty increasingly penalizes violations near the critical thresholds, bounded by a maximum penalty of 5.0 for exceeding critical limits.

To calculate the cumulative safety impact, we integrate the penalties over the prediction horizon T_h . We apply a temporal discount factor λ to deprioritize violations that occur

far in the future, reflecting the operator's window for manual intervention:

$$\bar{I}_{safety} = \frac{1}{T_h} \int_0^{T_h} e^{-\lambda t} \sum_{j \in \mathcal{V}} w_j \cdot \psi_j(t) dt \quad (7)$$

Furthermore, to provide a holistic consequence metric, we define $\bar{I}_{econ}$ as the normalized economic loss derived from equipment damage and operational downtime. The total predicted impact combines safety and economic factors using a weighting parameter $\alpha \in [0, 1]$:

$$\bar{I}_{total} = \alpha \bar{I}_{safety} + (1 - \alpha) \bar{I}_{econ} \quad (8)$$

The temporal discount factor λ in Eq. 7 was calibrated to 0.0028 s^{-1} ($\approx 0.168 \text{ min}^{-1}$), giving a 4.1-minute half-life. This gives high weight to immediate failures while strongly discounting slow anomalies that operators can usually handle manually.

The dynamic risk score R_{dyn} is then mapped to a 0–10 scale using a sigmoid function that focuses only on physical impact, after filtering alerts with IDS confidence below 0.7.

$$R_{dyn} = 10 \cdot \left(\frac{1}{1 + \exp(-k(\bar{I}_{total} - \bar{I}_0))} \right) \quad (9)$$

where $k = 5.0$ and $\bar{I}_0 = 0.5$. These parameters were tuned via grid search to minimize MAE against expert labels. The mapping keeps low physical violations near a low risk baseline while pushing catastrophic failures toward 10.

F. CPIQ Workflow

The CPIQ risk assessment pipeline operates in four phases:

Phase 1 - Attack Translation: Parse the IDS alert to extract the targeted network address (e.g., Modbus register 30001). Look up the corresponding physical variable in the tag database (e.g., LIT101). If no physical mapping exists, the alert is IT-only and assigned a low risk score.

Phase 2 - Simulation Initialization: Retrieve the current process state from sensor measurements. Initialize a shadow simulation with this state and inject the attack (sensor spoof, actuator override, or setpoint change).

Phase 3 - Forward Propagation: Simulate the process evolution over 30 minutes using the DT. At each timestep:

- Compute controller response to (potentially corrupted) sensor readings
- Update physical state using ODEs (Eq. 3)
- Accumulate safety violations using Eq. 6
- Terminate early if critical limits are exceeded

Phase 4 - Risk Scoring: Map the cumulative safety impact $\bar{I}_{safety}$ to a risk score using Eq. 9. Alerts with $R_{dyn} \geq 8.5$ trigger immediate escalation, while $R_{dyn} < 2.5$ are suppressed.

Performance optimization via Adaptive Quantization: Simulation results are cached for 5 minutes to skip redundant ODE computations. To avoid misclassification at safety thresholds (e.g., $x = 795\text{mm}$ quantized to 800mm), CPIQ uses adaptive quantization: coarse ($\Delta x_{coarse} = 20\text{mm}$) in safe regions and fine ($\Delta x_{fine} = 2\text{mm}$) when $\min |x - x_{crit}| < 50\text{mm}$. This achieves a 68% cache hit rate (vs. 47% static fine), cutting repeated-attack latency from 2.1s to 0.8ms without losing boundary accuracy.

G. Computational Performance

Average latency per alert: 2.1 seconds, dominated by ODE integration (1.8s for 1800 timesteps). With 8 parallel workers and 68% cache hit rate, the system achieves 226 alerts/minute throughput, sufficient for typical IDS loads (15-40 alerts/min normal operation, 120 alerts/min during scans). Early termination when critical limits are exceeded reduces average simulation time by 35%.

V. EXPERIMENTAL EVALUATION

A. Experimental Setup

1) *Dataset*: We evaluate CPIQ using the SWaT dataset [8], which includes 11 days of operation from a scaled water treatment plant: 7 days of normal data (946,722 samples at 1Hz) and 4 days containing 36 cyber-physical attacks across 51 sensors and 41 actuators.

To prevent data leakage, phases were strictly separated. The normal data was used only for DT calibration and EKF modeling. Of the 36 attacks, 6 were used for validation (tuning $\lambda, k, \bar{I}_0$), 18 for final testing (Table II), and 12 were excluded due to incomplete logs or overlapping injection windows.

Attack selection followed stratified sampling to ensure coverage of sensor spoofing and actuator override scenarios with varying impact levels. Two certified process safety engineers independently rated physical risk (0–10). Inter-rater reliability was strong (ICC = 0.87), and maximum disagreement on the test set was 1.5 points, indicating consistent ground truth.

Table II
ATTACK SCENARIOS FOR EVALUATION (18 ATTACKS, ICC = 0.87
INTER-RATER RELIABILITY)

ID	Attack Description	CVSS	Expert
<i>Critical Impact (Expert ≥ 9.0)</i>			
3	Pump P101 forced ON at max level	6.8	9.8
14	LIT101 spoofed -250mm (overflow)	5.3	9.5
18	MV101 valve stuck closed	7.1	9.2
25	Multi-stage P1+P2 coordination	7.8	9.7
<i>High Impact (Expert 7.0–8.9)</i>			
7	AIT202 pH sensor drift +1.5 units	4.9	7.8
12	P203 pump rapid cycling	6.2	7.5
21	LIT301 spoofed +150mm	5.8	7.2
29	Setpoint manipulation UIT	5.5	7.9
34	Coordinated low-rate attack	5.9	7.4
<i>Medium Impact (Expert 4.0–6.9)</i>			
23	LIT101 slow drift +0.5mm/min	4.1	6.8
5	FIT101 flow bias +10%	4.2	4.8
10	MV201 partial closure 60%	5.1	5.3
16	AIT402 temperature offset +3°C	3.8	4.5
27	Slow pH drift 30min	4.5	3.2
<i>Low Impact - IT-only (Expert < 3.0)</i>			
2	HMI historian corruption	7.9	1.8
9	SCADA workstation DoS	8.2	2.1
19	Network reconnaissance scan	5.4	1.2
31	Credential theft (no exec)	6.5	0.5

2) *Implementation Details*: Experiments ran on Intel i9-14900K (24 cores), 64GB RAM, and RTX 4070 GPU. CPIQ was implemented in Python 3.11 with SciPy RK45 solver (rtol=10⁻⁶, atol=10⁻⁸). The EKF state $x = [V, Q_{in}, Q_{out}]^T$ models tank volume and flows.

Process noise $Q = \text{diag}([10^{-6}, 10^{-7}, 10^{-7}])$ was set from calibration residuals. Measurement noise $R = \text{diag}([\sigma_{LIT}^2, \sigma_{FIT}^2])$ was computed from sensor statistics ($\sigma_{LIT} = 8.4$ mm, $\sigma_{FIT} = 0.15$ L/s). EKF consistency was checked using chi-square test on innovation. Simulations were parallelized with `multiprocessing.Pool` (8 workers).

Validation attacks were strictly separated from test attacks. Neural baselines were implemented in PyTorch 2.1.0 with GPU support.

3) *Baseline Methods*: We compare CPIQ with five baselines:

CVSS v3.1 Base & Environmental [10]: Industry IT standard. Environmental metrics configured based on SWaT asset criticality.

Dynamic Bayesian Attack Graph (DBAG) [11]: Probabilistic graph-based risk using network topology, without physical dynamics.

Reachability Analysis [17]: Formal method computing reachable state space to check safety violation within 30-minute horizon.

TIMESNet [14] and TranAD [15]: Deep time-series anomaly detection models trained on 7-day normal data. Their anomaly scores were mapped to 0–10 risk scale using percentile calibration on validation set.

Baseline rationale: CPIQ estimates physical consequence deterministically. Anomaly detectors are included to show that high anomaly score does not always mean high physical damage. Reachability is included to compare formal guarantee versus real-time feasibility in SOC operation.

4) *Evaluation Metrics*: We evaluate methods using:

- **Spearman correlation (ρ)**: Rank correlation with expert scores (higher better)
- **Mean Absolute Error (MAE)**: Average $|R_{pred} - R_{expert}|$ (lower better)
- **Critical Miss Rate (CMR)**: Fraction of critical attacks ($R_{expert} \geq 8.0$) scored below 7.0 (lower better)
- **Alert Suppression Rate (ASR)**: Fraction of low-impact attacks ($R_{expert} < 3.0$) correctly suppressed (higher better)
- **Latency**: Average seconds per alert (lower better, must be < 60s for real-time SOC)

B. Overall Risk Assessment Performance

Table III and Figure 2 present the quantitative comparison of CPIQ against the baseline methods across the 18 SWaT attack scenarios.

Correlation and Accuracy: CPIQ achieves the highest correlation ($\rho = 0.94$) and lowest MAE (0.70). Reachability is second ($\rho = 0.88$), confirming that physical modeling improves consequence estimation. ML models (TranAD, TIMESNet) reach only $\rho \approx 0.77$ because statistical anomalies do not always reflect real physical damage.

Real-Time Feasibility: Reachability has 0.0% critical misses but high latency (145.6 s per alert), which is impractical for busy SOC. CPIQ keeps similar reliability with 2.13 s latency (68× faster), offering a better accuracy–time trade-off.

Alert Suppression: CPIQ suppresses all IT-only attacks (100% ASR). ML baselines (e.g., TIMESNet, 25% ASR) often label scans or sensor noise as high risk, causing false positives and harder triage.

C. Attack Category Analysis

We analyze CPIQ’s performance stratified by attack type to identify strengths and limitations.

Sensor spoofing (MAE =0.59): CPIQ performs well because DT directly simulates how false sensor data changes

Table III
RISK ASSESSMENT PERFORMANCE COMPARISON ON SWAT DATASET

Method	Correlation $\rho \uparrow$	MAE $\downarrow$	Critical Miss % $\downarrow$	Alert Supp. Rate % $\uparrow$	Latency (sec) $\downarrow$	Paradigm
CVSS v3.1 Base [10]	0.38	4.12	75.0	0.0	0.002	Static IT
CVSS v3.1 Env [10]	0.51	3.57	50.0	25.0	0.002	Static IT
DBAG [11]	0.61	2.95	37.5	50.0	0.085	Topological
TIMESNet [14]	0.75	2.15	12.5	25.0	0.180	ML / Data-driven
TranAD [15]	0.77	1.98	12.5	50.0	0.140	ML / Data-driven
Reachability [17]	0.88	1.15	0.0	75.0	145.60	Formal Methods
CPIQ (Ours)	0.94	0.70	0.0	100.0	2.130	Co-Simulation




Figure 2. Risk assessment comparison across 18 SWaT attack scenarios. CPIQ consistently aligns with expert ground truth, successfully escalating all critical physical threats ($R \geq 8.0$) while correctly suppressing IT-only alerts (e.g., Attacks #19, #31).

controller action. In Attack #14 it correctly captures tank mass increase. DBAG (MAE=2.04) focuses on compromise probability, not on physical outcome, so error is higher.

Actuator override (MAE=0.71): In Attack #3 (pump forced ON), CPIQ predicts overflow at $t = 34s$ with $R_{dyn} = 9.7$ (expert: 9.8). TranAD (MAE=1.95) outputs 7.5, since actuator switch (0 to 1) looks small in feature space, although physical impact is large.

Multi-stage attacks (MAE=0.45): CPIQ models dependency between stages (e.g., P1 outflow to P2 inflow). TIMES-




Figure 3. Spearman correlation analysis between predicted risk scores and expert ground truth. CPIQ demonstrates near-perfect linear alignment ($\rho = 0.94$) compared to the dispersed predictions of static and topological methodologies.

Table IV
RISK SCORING PERFORMANCE BY ATTACK CATEGORY

Attack Category	CPIQ MAE	Best Baseline	Baseline MAE
Sensor Spoofing (6 attacks)	0.59	Reachability	1.05
Actuator Override (4 attacks)	0.71	TranAD	1.95
Setpoint Manipulation (2 attacks)	0.83	TIMESNet	2.10
Multi-stage Coordinated (2 attacks)	0.45	Reachability	1.12
IT-only Attacks (4 attacks)	0.98	DBAG	2.50
Overall (18 attacks)	0.70	–	1.15

Net and TranAD treat variables as flat vector, so physical direction between stages is not well represented.

IT-only attacks (MAE=0.98): This is weaker case for CPIQ. In Attack #2 (HMI corruption), CVSS is 7.9 but expert risk is 1.8. CPIQ detects no serious physical damage, but final score is 2.7 because IDS confidence still influences result. It shows difficulty to fully decouple cyber and physical parts.

Stealth attacks (MAE=0.3): In Attack #23 (slow drift +0.5mm/min), expert risk is 6.8. Level crosses safe limit (800mm) at $t = 8$ min and approaches critical (1000mm) at $t = 26$ min. With temporal discount ($\lambda = 0.168 \text{ min}^{-1}$) and quadratic penalty (Eq. 6), CPIQ gives $I_{safety} = 0.42$ and $R_{dyn} = 6.5$ ($\Delta = 0.3$). This shows CPIQ balances early and long-term impact reasonably.

D. Case Study: Attack #14 Deep Dive

Attack #14 is sensor spoofing that leads to tank overflow. The attacker modifies level sensor LIT101 in Tank T101 via Modbus write to register 30001, inserting value 250 mm lower than real level. The false reading remains for 8 minutes, so controller operates on wrong data. CVSS v3.1 assigns Base Score 5.3 and Environmental 6.1, while expert gives 9.5/10 due to severe physical consequence.

Comparison with Baselines for Attack #14:

Table V
RISK SCORES FOR ATTACK #14 (LIT101 SPOOFING OVERFLOW)

Method	Predicted Risk	Error $ \Delta $	SOC Action
Expert Label	9.5	–	(ground truth)
CVSS Env	6.1	3.4	Medium priority queue
DBAG	6.8	2.7	Medium-high queue
TIMESNet	7.6	1.9	High priority queue
TranAD	8.2	1.3	High priority queue
Reachability	9.0	0.5	CRITICAL escalation (Delayed)
CPIQ (Ours)	10.0	0.5	CRITICAL escalation (Real-time)

Operational Impact: CVSS Environmental (score=6.1) would place this alert in the "medium priority" queue behind higher-CVSS IT attacks. Average SOC response time for medium alerts is 45 minutes. By this time, the tank has already overflowed (occurred at $t = 312s$, or 5.2 minutes). CPIQ's score of 10.0 triggers immediate automated escalation (response SLA: < 5 minutes), enabling preemptive operator intervention.

E. Computational Performance Analysis

Table VI provides a detailed timing breakdown for CPIQ's risk assessment pipeline based on Attack #14.

Table VI
COMPUTATIONAL LATENCY BREAKDOWN (ATTACK #14)

Component	Time (ms)	% Total
<i>Phases 1 & 2: Translation and Initialization</i>		
Alert parsing & state estimation	75.6	3.55%
<i>Phase 3: DT Simulation</i>		
ODE integration (1800 steps)	1871.5	87.87%
$\hookrightarrow$ RK45 function evals	1677.1	78.74%
$\hookrightarrow$ Jacobian computations	194.4	9.13%
Safety constraint checking	182.5	8.57%
<i>Phase 4: Risk Score Computation</i>		
Sigmoid mapping & Aggregation	0.2	0.01%
Total Latency	2129.8	100.0%

Bottleneck Analysis: ODE integration dominates the pipeline (87.87% runtime). The RK45 solver uses adaptive timesteps; over a 30-minute horizon it averaged 1247 steps across 12 coupled equations per evaluation. To support SOC deployment, CPIQ applies early termination (halting at $t = 312s$ after critical overflow detection) and a discretized state-space cache ($\Delta x = 20mm$). With 8-worker parallelization and a 68% cache hit rate, throughput reaches 226 alerts/min, exceeding the 120 alerts/min IDS burst observed in SWaT.

F. Ablation Study and Sensitivity Analysis

We investigated the contribution of individual CPIQ mathematical components through a systematic ablation study (Table VII).

Table VII
ABLATION STUDY: IMPACT OF CPIQ FRAMEWORK COMPONENTS

Configuration	Correlation ρ	MAE	CMR %
Full CPIQ Architecture	0.94	0.70	0.0
w/o Physics (static CVSS fallback)	0.51	3.57	50.0
w/o Temporal Discount ($\lambda = 0$)	0.89	1.12	12.5
w/o State Estimation (raw sensors)	0.91	0.84	0.0
Simple Physics (algebraic, no ODEs)	0.82	1.54	12.5
<i>Oracle: Perfect Model & State</i>	0.97	0.41	0.0

Hyperparameter Sensitivity (λ): To validate the selection of the temporal discount factor, we conducted a sensitivity analysis on the disjoint validation set (Table VIII). The grid search evaluated $\lambda \in \{0.05, 0.10, 0.168, 0.25, 0.50\} \text{ min}^{-1}$. At $\lambda = 0.05$, slow-developing threats (e.g., long-term drifts) are under-discounted, leading to over-penalization and a high validation MAE of 1.34. Conversely, $\lambda = 0.50$ excessively discounts medium-term violations, effectively blinding the system to consequences beyond a 2-minute horizon and causing a 16.7% Critical Miss Rate (CMR) on the validation set. The empirically selected value of $\lambda = 0.168 \text{ min}^{-1}$ perfectly minimizes the MAE while maintaining a 0% CMR, strictly aligning the mathematical decay with the operational incident response windows.

Table VIII
HYPERPARAMETER SENSITIVITY ANALYSIS FOR λ (VALIDATION SET)

Discount Factor λ (min^{-1})	Validation MAE	Correlation ρ	CMR %
0.05	1.34	0.88	16.7
0.10	0.89	0.92	0.0
0.168 (Selected)	0.65	0.94	0.0
0.25	0.71	0.93	0.0
0.50	1.12	0.87	16.7

Physics Simulation: Without the DT, correlation drops from 0.94 to 0.51, showing physics-based simulation is essential.

ODE vs. Algebraic Models: Using steady-state approximations raises MAE to 1.54, highlighting the need for transient dynamics.

Temporal Discounting: $\lambda = 0$ over-penalizes slow threats; discounting aligns risk scoring with operator response.

Oracle Bound: Perfect-knowledge CPIQ gives MAE = 0.41; remaining error reflects expert disagreement (ICC = 0.87).

VI. DISCUSSION AND LIMITATIONS

CPIQ improves over static IT scoring, but practical deployment challenges remain.

A. Empirical Robustness and Adversarial Resilience

Deterministic risk scoring can still face adversarial manipulation. We therefore conducted stress tests targeting stealth drift, boundary evasion, model mismatch, and cache saturation (Table IX).

Stealthy Drift Resilience: A low-rate spoofing attack ($\delta = 0.1 \text{ mm/s}$), remaining within EKF measurement noise covariance R , initially avoided statistical detection. However, the physical mass-balance constraint (Eq. 3) forced gradual state divergence. CPIQ escalated risk to 9.42 at $t = 482s$. This detection window still provides operational lead time before

Table IX
SYSTEM ROBUSTNESS UNDER ADVERSARIAL AND ENVIRONMENTAL STRESS

Stress Scenario	Metric	Value	Risk Score
Stealthy Drift ($\delta = 0.1\text{mm/s}$)	Detection Lag	482 s	9.42 (Crit.)
Cache Flooding ($N = 1000$)	Latency	0.8 ms	10.0 (Crit.)
Efficiency Loss ($-10\%\eta$)	Pred. Delay	+34 s	8.76 (High)
Quantization Error ($\Delta x = 20\text{mm}$)	Accuracy Loss	< 0.5%	8.95 (High)

the 15-minute SWaT shutdown SLA, indicating that physics-based scoring establishes a deterministic lower bound against stealth attacks.

Cache Integrity: To evaluate cache poisoning resistance, we flooded memory with 1,000 benign state-action pairs before injecting Attack #14. Due to fine-grained state quantization ($\Delta x = 20\text{mm}$), CPIQ discarded stale hashes and processed the critical event in 0.8ms, reaching the maximum risk score (10.0).

B. Model-Plant Mismatch and Deployment Scalability

DT accuracy depends on alignment between simulated physics and plant reality. Mechanical degradation (e.g., reduced η_{pump}) introduces prediction lag. A 10% efficiency loss caused a 34-second delay in overflow prediction. Although $R_{\text{dyn}} = 8.76$ remained above the escalation threshold (8.5), prolonged drift could eventually produce false negatives. Continuous EKF residual monitoring and periodic recalibration are therefore required.

Finally, while CPIQ avoids the state-space explosion of formal reachability (reducing latency from 145s to 2.13s), building high-fidelity ODE models for large-scale refineries remains resource-intensive. A tiered deployment strategy is recommended: static CVSS scoring for non-critical IT layers, and CPIQ reserved for Safety Instrumented Systems (SIS) and primary process actuators.

VII. CONCLUSION AND FUTURE WORK

This paper introduced the Cyber-Physical Impact Quantification (CPIQ) framework to reduce the semantic gap between network alerts and real physical consequences. Unlike static IT risk models or purely statistical ML detectors, CPIQ relies on a calibrated DT to perform deterministic, physics-based simulations. Evaluation on the SWaT dataset shows that combining real-time state estimation with thermodynamic and kinematic ODE models enables accurate consequence prediction. CPIQ achieved a Spearman correlation of 0.94 with expert safety assessments, while reducing critical triage errors and SOC alert fatigue from IT-only false positives, all within sub-second response latency.

Future work will extend CPIQ to decentralized multi-plant environments using federated state estimation, and explore reinforcement learning to model adaptive, physics-aware attackers. This will allow systematic boundary testing against optimized stealth attacks and further strengthen robustness in critical infrastructure deployments.

ACKNOWLEDGEMENTS

The authors acknowledge the financial support of the project 0522_CAPABILITIC_4_E, co-funded by the European Regional Development Fund (ERDF) through the Interreg VI-A Spain-Portugal (POCTEP) program 2021-2027.

REFERENCES

- [1] M. Homaei, O. Mogollón-Gutiérrez, J. C. Sancho, M. Avila, and A. Caro, "A review of digital twins and their application in cybersecurity based on artificial intelligence," *Artificial Intelligence Review*, vol. 57, no. 8, Jul. 2024.
- [2] V. Barbuto, C. Savaglio, E. A. Lee, and G. Fortino, "Engineering opportunistic digital twins with lingua franca," *Future Generation Computer Systems*, vol. 178, p. 108262, 2026.
- [3] N. A. Alghanmi, "Leveraging digital twins with hybrid deep learning model for robust intrusion detection system in smart city environment," *Fusion: Practice and Applications*, vol. 19, no. 1, pp. 201–221, 2025, received: October 28, 2024; Revised: January 12, 2025; Accepted: February 07, 2025.
- [4] L. Pincioli, S. A. Hosseini, M. Chen, M. V. C. Mesa, T. M. Coscia, J. P. Futalef, S. Marchetti, L. Miqueles, S. T. Menza, and E. E. Zio, "Risk assessment for modern industry," *Reliability Engineering and System Safety*, vol. 269, 2026.
- [5] T. Vairo, S. Guarino, A. Benvenuto, B. Fabiano, and R. Setola, "Emergent risks in complex systems: A bayesian perspective on uncertainty and prediction," *Reliability Engineering and System Safety*, vol. 270, 2026.
- [6] L. Zhao, T. Ge, Q. Zhu, L. Zhao, Z. Xing, Y. Yan, W. Han, and G. Qi, "Dynamic risk analysis for emergency repair of sudden natural gas pipeline leakages," *Journal of Loss Prevention in the Process Industries*, vol. 100, 2026.
- [7] A. Bouafia, M. Bougofa, W. Benhamlaoui, and M. Rouaïnia, "Integrating functional resonance and bayesian networks for quantitative risk assessment: Application to adrar's refinery pre-fractionation," *Quality and Reliability Engineering International*, vol. 42, pp. 503–523, 2026.
- [8] A. Mathur and N. O. Tippenhauer, "Swat: A water treatment testbed for research and training on ics security," in *Proceedings of the International Workshop on Cyber-Physical Systems for Smart Water Networks (CySWater)*, Apr. 2016.
- [9] M. Homaei, A. Caro, J. C. S. Núñez, and J. A. Díaz, "The role of artificial intelligence in digital twin's cybersecurity," in *Proceedings of XVII Reunión Española sobre Criptología y Seguridad de la Información (RECSI 2022)*, Santander, Spain, Nov 2022.
- [10] FIRST.org, "Common vulnerability scoring system v3.1: Specification document," Forum of Incident Response and Security Teams, Tech. Rep., 2019. [Online]. Available: <https://www.first.org/cvss/v3.1/specification-document>
- [11] M. Khouzani, Z. Liu, and P. Malacaria, "Scalable min-max multi-objective cyber-security optimisation over probabilistic attack graphs," *European Journal of Operational Research*, vol. 278, no. 3, pp. 894–903, 2019.
- [12] S. Guarino, L. Faramondi, G. Oliva, E. del Prete, F. Flammini, and R. Setola, "Hybrid knowledge-based decision support system for intrusion response in industrial cyber-physical systems," *Future Generation Computer Systems*, vol. 179, p. 108306, 2026.
- [13] Anonymous, "An improved autoencoder methodology for anomaly detection in industrial control systems," *Informa UK Limited, trading as Taylor & Francis Group*, 2024.
- [14] H. Wu, T. Hu, Y. Liu, H. Zhou, J. Wang, and M. Long, "Timesnet: Temporal 2d-variation modeling for general time series analysis," in *The Eleventh International Conference on Learning Representations (ICLR)*, 2023.
- [15] S. Tuli, G. Casale, and N. R. Jennings, "Tranad: deep transformer networks for anomaly detection in multivariate time series data," *Proceedings of the VLDB Endowment*, vol. 15, no. 6, pp. 1201–1214, 2022.
- [16] K. Cho, J. Lee, and S. B. Kim, "Sfaformer: Sampling frequency-aware transformer specialized for unsupervised anomaly detection in irregular multivariate time series," *Information Sciences*, vol. 736, p. 123094, 2026.
- [17] R. Lanotte, M. Merro, A. Munteanu, and L. Viganò, "A formal approach to physics-based attacks in cyber-physical systems," *ACM Transactions on Privacy and Security (TOPS)*, vol. 23, no. 1, pp. 1–41, 2020.
- [18] J. Chen, A. Kemmeugne, J. Yan, M. Ghafouri, M. Kassouf, and M. Debbabi, "An sdn-based framework for cyber-physically coordinated voltage support of virtual power plants against dos attacks," *IEEE Transactions on Smart Grid*, vol. 17, no. 1, pp. 617–633, 2026.
- [19] F. Moomtaheen, S. S. Bagui, S. C. Bagui, and D. Mink, "Extended isolation forest for intrusion detection in zeek data," *Information*, vol. 15, no. 7, p. 404, Jul. 2024.

A Review of: “Assessing the impact of Modbus/TCP protocol attacks on Critical Infrastructure: WWTP case study.”

Valentine Machaka^{1,2}
vmachaka@ceit.es

Saioa Arrizabalaga^{1,2}
sarrizabalaga@ceit.es

Santiago Figueroa-Lorenzo²
sfigueroa@external.unav.es

Josune Hernantes²
jhernantes@unav.es

¹CEIT-Basque Research and Technology Alliance (BRTA), Manuel Lardizabal 15, 20018 Donostia / San Sebastián, Spain.

²Universidad de Navarra, Tecnun, Manuel Lardizabal 13, 20018 Donostia / San Sebastián /Spain.

Resumen—Cyberattacks pose significant risks to industrial control systems (ICS), particularly in critical sectors such as water. This study presents a controlled, reproducible virtualised ICS testbed based on the IEC 62264 Industrial Automation Pyramid (IAP), featuring a scalable multi-layered network architecture supporting multiple ICS protocols. Understanding the implications of these cyberattacks is essential for evaluating their environmental and economic repercussions to develop defensive strategies and implement security mechanisms. The testbed includes an Operational Technology (OT) environment with a digital twin of a Wastewater Treatment Plant (WWTP) developed using MATLAB/Simulink, OpenPLC, and SCADA-LTS. The MITRE ATT&CK adversary emulation technique was used to assess the impact of Modbus/TCP protocol attacks targeting levels 1 and 2 of the IAP. Findings highlight the necessity for threat emulation, vulnerability assessment, and operational impact analysis, while emphasising early detection to minimise risks to operational integrity and environmental safety.

Index Terms—ICS Security, Digital Twins, Sensor Networks, Adversary Emulation, Threat Assessment, Critical Infrastructure Protection

Tipo de contribución: *Research already published [1].*

I. INTRODUCTION

CRITICAL-INFRASTRUCTURES (CIs) rely on industrial control systems (ICS) for the reliable delivery of essential services, with water entities classified as highly critical under the EU NIS-2 directive. Modern ICS components—including SCADA systems, PLCs, and IoT devices—increasingly communicate over TCP/IP protocols such as Modbus/TCP, exposing them to significant attack surfaces.

Recent incidents underscore this risk: the 2021 Florida water treatment hack, the Maroochy Shire SCADA breach, a 2023 Pennsylvania water authority attack, and ransomware campaigns targeting utilities in Portugal and Italy all demonstrate the growing threat to critical water infrastructure. Researching defences in live production environments is itself hazardous, motivating the need for dedicated testbeds.

This work presents a scalable, multilayered virtualised ICS testbed following the IEC 62264 Industrial Automation Pyramid (IAP), incorporating a MATLAB/Simulink digital twin of a Wastewater Treatment Plant (WWTP) alongside OpenPLC and SCADA-LTS.

Using MITRE ATT&CK adversary emulation, Modbus/TCP attacks targeting IAP levels 1 and 2 are assessed

to analyse their operational impact on the WWTP process—bridging the gap between theoretical risk and practical assessment as outlined in IEC 62443-3-2.

Key contributions include the testbed architecture itself, Modbus/TCP attack impact analysis, threat emulation demonstration, and misuse-based threat detection in an industrial process context.

II. RELATED WORK

Several virtual, physical, and hybrid ICS testbeds have been proposed for cybersecurity research. Virtual implementations incorporate key components like PLCs, HMIs, and sensors but oversimplify physical processes, limiting analysis to programmed behaviour rather than real industrial dynamics.

Physical testbeds offer greater realism but lack the flexibility to simulate diverse ICS scenarios cost-effectively, while hybrid approaches only partially address this tension. Water-sector testbeds in particular focus on network-level attacks without modelling underlying chemical or physical processes.

A recurring gap across the reviewed literature is the prioritisation of attack emulation over detection, with only one of the eight reviewed works implementing a monitoring mechanism. Additionally, none of the reviewed testbeds address compliance with IEC 62264 or IEC 62443-3-2 standards.




Figura 1. The virtualised ICS testbed - GNS3 topology.

III. IMPLEMENTATION

III-A. Virtualised ICS Testbed

The virtualised ICS testbed follows the IEC 62264 IAP, segmenting the IT/OT environment into zones corresponding to IAP levels 0–3. As shown in Figure 1, the GNS3¹ to-

¹GNS3: <https://docs.gns3.com/docs/>

poloogy includes IT devices such as routers, switches, and firewalls, alongside an OT environment of containerised components: OpenPLC, SCADA-LTS, a compromised HMI, and a MATLAB/Simulink WWTP model.




Figura 2. Wastewater Treatment Plant (WWTP) MATLAB/Simulink.

These components communicate via Modbus/TCP and UDP. The PLC maps WWTP sensors and actuators to the SCADA; control signals from the SCADA pass through the PLC to variable frequency drives (VFDs) via UDP, which drive the Q_{ri} , Q_w , and Q_{air} pumps in the Simulink model. Sensors measuring dissolved oxygen (DO), temperature (T), nitrate (NO_3-N), and ammonium nitrogen (NH_4-N) return values to the PLC via UDP, which forwards them to the SCADA over Modbus/TCP (Figure 2).

III-B. Risk Assessment, Adversary Emulation & Threat Detection

Attacks on level 0 risk catastrophic consequences, including environmental damage and process destabilisation, while attacks on levels 1 and 2 may cause denial of control (T0813), loss of view (T0829), loss of availability (T0826), or manipulation of control (T0831).

To emulate these threats, four open-source tools were employed following MITRE ATT&CK ICS tactics: Nmap for host discovery and service enumeration, ModTester—an in-house Modbus penetration tool—to exploit the protocol’s lack of authentication, Metasploit MSFConsole for register enumeration and command injection, and Ettercap for MiTM interception and traffic manipulation. The attacker is assumed to have lateral network access within the OT environment without physical presence.

Security Onion², a network security monitoring and intrusion detection system, was deployed at levels 1 and 2 via port mirroring, using Suricata as the primary detection engine with signatures derived from Wireshark traffic analysis.

IV. RESULTS

Communication performance was evaluated by measuring Modbus/TCP response times and one-way UDP latency. Modbus/TCP averaged 10.8ms round-trip and 28.3ms one-way latency, spiking to 133ms and 147ms worst-case. UDP telemetry showed the widest variation, averaging 252ms and peaking near 1.6 seconds, while control signal processing averaged 50ms and PLC-Simulink interactions remained stable at 62.6ms average. Overall, average latency and response times

remained below 100ms, acceptable for ICS, though telemetry spikes remain the most significant performance concern.

Adversary emulation demonstrated that attacks on the WWTP process produce measurable and environmentally significant consequences. Manipulating the aeration rate ($K_L a$) via MiTM and parameter modification caused an immediate collapse in dissolved oxygen and nitrate to 0mg/L, while ammonium spiked to 35mg/L within hours — conditions that suppress nitrifying bacteria, impair denitrification, and risk eutrophication in downstream water bodies. Recovery required approximately eight days.

Conversely, increasing aeration to $300d^{-1}$ elevated dissolved oxygen and nitrate while reducing denitrification efficiency, releasing excess total nitrogen to the environment and increasing energy consumption, with aeration known to account for up to 67 % of energy use in biological treatment. Recovery in this case was less than a day.

Attacks on the internal recirculation flow rate (Q_{ri}) produced similar disruption. Reducing Q_{ri} to $5000m^3/d$ caused nitrate accumulation in the aerobic tank due to insufficient transfer to the anoxic zone, with a recovery time of one day during which effluent remained contaminated.

Increasing Q_{ri} to $220,000m^3/d$ reduced hydraulic retention time in the anoxic tank, introduced dissolved oxygen into the denitrification zone, and caused nitrate to exceed 10mg NO_3-N — degrading effluent quality with a two-day recovery. Across all scenarios, the evasion technique ensured operators had no visibility of the ongoing manipulation, demonstrating that such attacks could persist undetected for days or weeks in a real environment.

The IDS successfully identified all emulated attacks; however, detection alone is insufficient, highlighting the need for active countermeasures capable of real-time response within ICS environments.

V. CONCLUSION

This paper presented a multilayered virtualised ICS testbed based on a WWTP digital twin, OpenPLC, and SCADA-LTS for cybersecurity testing and impact analysis, complemented by a Security Onion SIEM detection mechanism. Adversary emulation demonstrated that Modbus/TCP attacks produce measurable environmental and business consequences, including process destabilisation, regulatory exposure, and recovery costs. Since wastewater quality monitoring is not fail-proof, detection gaps are significant, underscoring the need for layered defences combining IDS, AMTD, and EDR mechanisms.

Future work will focus on implementing and evaluating countermeasures for real-time detection and response, extending adversary emulation to multi-layered attack scenarios, and incorporating additional ICS protocols such as OPC-UA and Profinet. Testbed fidelity will be enhanced through hybrid physical-virtual configurations, more sophisticated digital twins, and risk-based cybersecurity assessment mechanisms.

REFERENCIAS

- [1] V. Machaka, S. Figueroa-Lorenzo, S. Arrizabalaga, B. Elduayen-Echave, and J. Hernantes, “Assessing the impact of modbus/tcp protocol attacks on critical infrastructure: Wwtp case study,” *Computers and Electrical Engineering*, vol. 126, p. 110485, 2025. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0045790625004288>

²Security Onion: <https://docs.securityonion.net/en/2.4>

Towards a sustainable cybersecurity framework for Agriculture 4.0 based on a systematic analysis of proposals

DiegoF BustamanteV, Luis E. Sánchez, David G. Rosado, Antonio Santos-Olmo,
Eduardo Fernández-Medina, José L. Ruiz-Catalán
GSyA research group. Universidad de Castilla-La Mancha
Escuela Superior de Informática, Ciudad Real
diegofernando.bustamante@alu.uclm.es,
{luise.sanchez,david.grosado,antonio.santosolmo,eduardo.fdezmedina, joseluis.ruiz}@uclm.es

Resumen—Industry 4.0 technologies are transforming agriculture into Agriculture 4.0, enabling modernisation, automation, and greater sustainability. However, this transition introduces new risks and highlights the need for frameworks that integrate cybersecurity, artificial intelligence, and sustainability. This paper identifies gaps in existing approaches through a systematic review and proposes the QUILLAQUA framework, which combines AI, IoT, and cybersecurity to optimise water and nutrient management in hydroponic systems. The framework aims to improve efficiency, data security, and sustainability, supporting the transition to more resilient and digitalised agricultural practices.

Index Terms—Digital agriculture, Artificial intelligence, Cybersecurity, Sustainability

Tipo de contribución: Investigación ya publicada

I. INTRODUCTION

Agriculture is facing escalating challenges driven by climate change, global population growth, and the limited availability of freshwater resources, all of which demand a substantial increase in sustainable food production. In this context, Agriculture 4.0 technologies—particularly artificial intelligence, the Internet of Things, and cyber-physical systems—enable precise resource management, process automation, and improved productivity. However, the widespread adoption of these digital technologies also introduces significant cybersecurity risks and raises concerns regarding their actual contribution to environmental sustainability. To address these gaps, the article proposes the QUILLAQUA framework, an integrated approach that combines artificial intelligence, IoT, and cybersecurity within hydroponic systems to optimize water and nutrient management while ensuring data security and supporting sustainable digital agriculture.

II. OVERVIEW OF TECHNOLOGICAL ADVANCES IN AGRICULTURE

Modern agriculture has progressively integrated digitalisation, automation, and emerging technologies such as artificial intelligence, IoT, and cyber-physical systems to improve productivity, resource efficiency, and environmental sustainability. These technologies enable real-time monitoring, precision irrigation and fertilisation, and data-driven decision-making, but they also increase exposure to cybersecurity threats affecting data integrity and operational continuity. Consequently, the convergence of AI, cybersecurity, and sustainability is




Figura 1. Visual summary of the screening process.

considered essential for resilient Agriculture 4.0 systems, although current research still lacks fully integrated approaches addressing all three dimensions simultaneously.

III. SYSTEMATIC REVIEW

This section presents a systematic literature review examining how artificial intelligence, cybersecurity, and sustainability are jointly applied in digital agriculture. From an initial set of 370 publications, 48 relevant studies were selected and classified into methodologies, frameworks, models, techniques, processes, and other contributions to analyse trends and gaps (see Figure 1).

The analysis shows that most research focuses on technological optimisation through AI, IoT, and automation, while integrated approaches that simultaneously address cybersecurity and sustainability remain limited. In particular, security is often treated as a secondary aspect, and sustainability is rarely considered in conjunction with intelligent and interconnected systems.

Moreover, many existing proposals lack practical validation, present limited adaptability to real agricultural environments, and do not support dynamic or continuous risk management. These limitations reveal a clear gap in the development of comprehensive solutions capable of ensuring efficiency, security, and sustainability in a unified manner.

These findings establish the knowledge base and highlight the key challenges that motivate the development of the proposed QUILLAQUA framework.




Figura 2. Summary of characteristics.

IV. ANALYSIS AND IMPLEMENTATION OF SYSTEMATIC REVIEW RESULTS

The analysis of the 48 selected studies reveals strong research emphasis on artificial intelligence, IoT, and data-driven technologies in digital agriculture, with growing links to sustainability and cybersecurity. However, comparative evaluation against defined scientific and technological objectives shows that most proposals address these dimensions only partially, lacking comprehensive integration, cost-effective implementation, and real-world validation. The results highlight persistent gaps in sector-specific risk analysis, knowledge reuse, and scalable deployment, demonstrating the need for holistic frameworks that simultaneously ensure technological efficiency, environmental sustainability, and cybersecurity resilience in Agriculture 4.0. Figure 2 illustrates the contribution of recent studies to key characteristics of digital and sustainable agriculture, highlighting underexplored areas such as agricultural risk analysis, AI application, digitalisation management, cybersecurity, and global applicability.

V. ANALYSIS OF DESIRABLE CHARACTERISTICS AND PROPOSALS IN AGRICULTURE

The review of desirable characteristics across 48 studies reveals substantial limitations in current digital-agriculture proposals, particularly regarding tailored cybersecurity strategies, sustainability integration, affordability, and practical applicability. Most solutions lack adaptation to specific agricultural contexts, exceed cost thresholds, and provide limited mechanisms for knowledge management or large-scale deployment. In response to these deficiencies, the QUILLAQUA framework is proposed as a complementary approach that integrates specialised cybersecurity protocols, resource-optimisation mechanisms, and modular, low-cost design adaptable to diverse agricultural scenarios. This framework aims to bridge gaps in technical customisation, contextualised security, and scalability, supporting the gradual modernisation of sustainable digital agriculture systems.

VI. THE QUILLAQUA FRAMEWORK

Based on the identified gaps in existing digital-agriculture approaches, this section introduces the QUILLAQUA framework as an integrated solution combining artificial intelligence, IoT, cybersecurity, and sustainability for hydroponic agriculture. The framework enables real-time monitoring and




Figura 3. QUILLAQUA Framework.

automated control of environmental variables—such as temperature, pH, and nutrient levels—through distributed sensors and AI-driven decision systems, while incorporating encryption and blockchain mechanisms to ensure data integrity and protection against cyber threats. In addition, QUILLAQUA promotes sustainable resource management through water recycling, energy optimisation, and continuous environmental assessment, and supports adoption via training and knowledge-sharing platforms. Overall, the framework aims to enhance efficiency, security, and long-term sustainability in digital agriculture systems. Figure 3 presents the proposed QUILLAQUA framework, which integrates advanced systems to optimise hydroponic agriculture within an intelligent and sustainable approach.

VII. CONCLUSIONS

The study highlights that current digital-agriculture research rarely integrates artificial intelligence, cybersecurity, and sustainability in a unified way, often adapting technologies from other sectors without addressing agriculture-specific conditions. To bridge this gap, the QUILLAQUA framework is proposed as an integrated approach for secure and sustainable hydroponic agriculture, though its effectiveness requires validation through real-world case studies and supported adoption strategies.

AGRADECIMIENTOS

This work has been developed thanks to the financing provided by the following projects: Di4SPDS projects (CHIST-ERA grant - PCI2023145980-2) funded by MCIN/AEI and co-funded by the European Union, KOSMOS-UCLM (PID2024-155363OB-C44) financed by MCIN/AEI/ 10.13039/501100011033; ALBA-UCLM (TED2021-130355B-C31) financed by CIN/AEI/10.13039/501100011033/ Unión Europea NextGenerationEU/PRTR, and MESIAS (2022-GRIN-34202) financed by FEDER.

REFERENCIAS

[1] DiegoF BustamanteV, Luis E. Sánchez, David G. Rosado, Antonio Santos-Olmo, Eduardo Fernández-Medina: "Towards a sustainable cybersecurity framework for Agriculture 4.0 based on a systematic analysis of proposals", en *Computers & Security*, vol. 159, n. 104650, 2025. <https://doi.org/10.1016/j.cose.2025.104650>

A summary of Untouchable and Cancelable Biometrics: Human Identification Using Radar-Based Heart Signals

Daniel Foronda-Pascual, Carmen Camara, Pedro Peris-Lopez
Computer Science Department, Carlos III University of Madrid (UC3M), Spain
{daniel.foronda, mariacarmen.camara, pedro.peris}@uc3m.es

Abstract—This paper presents a cancelable biometric identification system based on contactless heart signals acquired via continuous-wave radar. Captured signals are transformed into scalograms for feature extraction using Convolutional Neural Networks (CNNs). Privacy is ensured by converting these features into protected templates using Gaussian Random Projection (GRP) prior to classification via a Multilayer Perceptron (MLP). The proposed method achieves 91.20% accuracy, reaching 95.40% in resting scenarios, and demonstrates that domain-specific CNNs outperform traditional transfer learning models.

Index Terms—Biometrics, cancelable biometrics, privacy, radar, heart signals.

Type of contribution: Research already published [1]

I. INTRODUCTION

Physiological biometrics are increasingly used in healthcare for patient identification and monitoring, offering advantages over traditional authentication methods, such as convenience, fraud resistance, and the potential for continuous monitoring. However, the use of sensitive physiological data raises significant privacy and security concerns. *Cancelable biometrics* provide a solution by applying irreversible transformations to original biometric traits, producing protected templates that are revocable, diverse, and non-invertible [2]. This ensures secure identification while mitigating risks in case of data compromise.

Electrocardiogram (ECG) signals have demonstrated high accuracy for biometric identification, but their contact-based acquisition limits usability and continuous monitoring. *Continuous-Wave (CW) radar* offers a non-contact alternative by detecting minute chest wall displacements caused by cardiac activity via the Doppler Effect [3]. This technology enables unobtrusive biometric acquisition, suitable for scenarios where contact sensors are impractical.

Despite progress in radar-based identification, most existing approaches lack mechanisms for template protection and have not been thoroughly evaluated under varying physiological conditions. This study addresses these gaps by proposing the first cancelable identification system for contactless CW-radar cardiac signals and evaluating its robustness under realistic physiological variability.

The main contributions of this work are:

- The first cancelable identification system using contactless CW-radar cardiac signals.
- Integration of Gaussian Random Projection (GRP) to generate protected templates without degrading identification performance.
- Comprehensive evaluation of physiological variability (five scenarios) on identification accuracy.
- Comparative analysis of feature extraction using domain-specific CNNs trained from scratch versus transfer learning with pre-trained networks on scalograms.

II. RELATED WORK

Cardiac-based identification has traditionally relied on ECG signals, achieving high accuracies with deep learning architectures [4]. However, ECG requires physical contact, limiting its use in non-intrusive monitoring. CW radar addresses this by detecting chest wall displacements via the Doppler effect. While studies have used CW radar for identification using heartbeats or spectrograms [3], it remains a nascent field with limited exploration of privacy-preserving mechanisms.

Cancelable biometrics protect privacy by applying irreversible transformations to biometric data, ensuring that original traits cannot be recovered if a template is compromised [5]. Gaussian Random Projection (GRP) has been explored as a cancelable transformation, projecting features onto random subspaces in biometric modalities such as iris or fingerprints [6]. Although cancelable schemes exist for ECG, to the best of our knowledge, no prior work has integrated these techniques with non-contact radar signals. This paper fills that gap by combining CW-radar processing with GRP-based protection.

III. MATERIALS AND METHODS

A. Dataset and Preprocessing

We used the publicly available Erlangen University Hospital dataset [7], comprising contactless CW-radar recordings from 30 subjects across five scenarios: Resting, Valsalva, Apnea, Tilt-up, and Tilt-down. The radar captured thoracic movements resulting from cardiac activity, respiration, and body motion using a bi-static antenna setup with a laser for alignment. Raw I/Q signals were segmented into 10-second windows, demodulated using arctangent ellipse fitting [8], and filtered via Maximal Overlap Discrete Wavelet Transform (MODWT) to isolate cardiac dynamics. Each window was subdivided into 4-second frames for data augmentation. Scalograms were generated using a Continuous Wavelet Transform (CWT) with a Morlet wavelet, providing a time-frequency representation suitable for CNN-based classification. The last 20% of windows per subject were reserved for testing, implementing a temporal split to simulate real-world conditions.

B. Feature Extraction

Features were extracted from scalograms using two strategies: (i) transfer learning with five pre-trained CNNs (ResNet50, DenseNet, ShuffleNet, VGG-19, Xception), fine-tuning the final layers, and (ii) a custom CNN with five convolutional layers trained from scratch. Each convolutional layer included batch normalization, ReLU activation, and max pooling, followed by fully connected layers producing class probabilities.

C. Cancelable Template Generation and Classification

Extracted features were transformed into cancelable templates using GRP [9], which projects high-dimensional vectors onto a lower-dimensional space while approximately preserving distances according to the Johnson-Lindenstrauss lemma. Templates were classified




Fig. 1. Overview of the identification process.

using a Multilayer Perceptron (MLP) with three hidden layers and dropout (0.2). Frame-level predictions were aggregated via majority voting to determine the final class for each 10-second window.

IV. RESULTS AND DISCUSSION

A. Feature Extraction: Transfer Learning vs. Custom CNN

We compared five pre-trained architectures using transfer learning against a custom CNN trained specifically on heart-signal scalograms. As shown in Table I, the Customized CNN consistently outperformed all pre-trained models, achieving 89.46% window accuracy across all scenarios and 96.16% in the resting state. This suggests a domain mismatch between natural images (ImageNet) and biometric scalograms.

TABLE I
ACCURACY (%) USING DIFFERENT FEATURE EXTRACTORS

Network	All scenarios		Resting scenario	
	Win. acc.	Frame acc.	Win. acc.	Frame acc.
ResNet50	88.32	77.88	93.09	87.92
VGG-19	85.88	77.72	89.51	84.57
Xception	85.15	74.36	92.07	85.70
DenseNet	84.35	71.00	91.30	82.54
ShuffleNet	80.22	67.72	87.72	75.34
Custom CNN	89.46	80.87	96.16	91.09

Additionally, to understand this performance, we applied the Convolutional Block Attention Module (CBAM) for interpretability. The attention maps reveal that the network prioritizes mid-to-high frequency regions of the scalogram, which contain the most discriminative biometric information.

B. Scenario-Based Performance

The system's robustness was tested across various physiological states. Table II shows that while "Resting", "TiltDown", and "Valsalva" achieve high accuracies (> 94%), "Apnea" and "TiltUp" are more challenging due to heart rate variability and reduced training data.

TABLE II
MODEL ACCURACY PER SCENARIO (CUSTOM CNN + GRP)

Scenario	Acc (%)	Scenario	Acc (%)
Resting	95.40	TiltDown	95.51
Valsalva	94.87	TiltUp	78.19
Apnea	74.75	Overall	91.20

Finally, the majority voting strategy provides a confidence metric. Windows predicted with more than 90% frame-consensus showed a 99.91% success rate, demonstrating the reliability of the fusion approach.

V. DISCUSSION AND CONCLUSIONS

The results demonstrate that contactless cancelable identification via CW-radar is not only feasible but also achieves performance levels competitive with traditional ECG-based methods. While some ECG-based cancelable systems report accuracies exceeding 99%, these often rely on random train-test splits. In contrast, our study employs a temporal split to mirror real-world applications, achieving a robust 95.40% accuracy in resting scenarios.

The proposed GRP-based system effectively satisfies the four essential properties of cancelable biometrics defined by the ISO/IEC 24745 standard: (i) Revocability, as new templates can be generated by changing the projection seed; (ii) Non-invertibility, due to the non-bijective nature of the dimensionality reduction; (iii) Diversity, allowing unique templates for different applications; and (iv) Performance, as identification accuracy remains stable even under significant compression.

Reliability is further enhanced by the majority voting strategy. By implementing a 50% confidence threshold, the system achieves an overall accuracy of 97.85%, successfully filtering out the physiological noise inherent in dynamic states like Apnea or Tilt-up.

In conclusion, this research provides the first evidence of a secure, contactless identification system using heart signals. With the inherent hygiene advantages of radar technology, this approach is a strong candidate for continuous monitoring in smart healthcare environments. Future work will explore multi-modal fusion with respiratory signals to further mitigate random body movement (RBM) in non-laboratory settings.

REFERENCES

- [1] D. Foronda-Pascual, C. Camara, and P. Peris-Lopez, "Untouchable and cancelable biometrics: Human identification in various physiological states using radar-based heart signals," *IEEE Journal of Biomedical and Health Informatics*, 2025.
- [2] M. Rawat and N. Kumar, "Cancelable biometrics: a comprehensive survey," *Artificial Intelligence Review*, vol. 53, 06 2020.
- [3] K. Shi, C. Will, R. Weigel, and A. Koelpin, "Contactless person identification using cardiac radar signals," in *2018 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*, 2018, pp. 1–6.
- [4] O. Ozaltin and O. Yeniay, "A novel proposed cnn-svm architecture for ecg scalograms classification," *Soft Comput.*, vol. 27, pp. 4639–4658, April 2023. [Online]. Available: <https://doi.org/10.1007/s00500-022-07729-x>
- [5] N. Ratha, J. Connell, and R. Bolle, "Enhancing security and privacy in biometrics-based authentication systems," *IBM Systems Journal*, vol. 40, pp. 614–634, 01 2001.
- [6] R. Rani, R. Dhir, and K. Sonkar, "Random projection-based cancelable iris biometrics for human identification using deep learning," *Arabian Journal for Science and Engineering*, vol. 49, pp. 3815–3828, March 2024, received 31 March 2022, Accepted 24 July 2023, Published 19 August 2023, Issue Date March 2024. [Online]. Available: <https://doi.org/10.1007/s13369-023-08190-0>
- [7] S. Chellenberger, K. Shi, T. Steigleder *et al.*, "A dataset of clinically recorded radar vital signs with synchronised reference sensor signals," *Sci Data*, vol. 7, p. 291, 2020. [Online]. Available: <https://doi.org/10.1038/s41597-020-00629-5>
- [8] M. Zakrzewski, A. Singh, E. Yavari, X. Gao, O. Boric-Lubecke, J. Vanhala, and K. Palovuori, "Quadrature imbalance compensation with ellipse-fitting methods for microwave radar physiological sensing," *IEEE Transactions on Microwave Theory and Techniques*, vol. 62, no. 6, pp. 1400–1408, 2014.
- [9] E. Bingham and H. Mannila, "Random projection in dimensionality reduction: applications to image and text data," in *Proceedings of the seventh ACM SIGKDD international conference on Knowledge discovery and data mining*, 2001, pp. 245–250.

Arquitectura de comando y control basada en roles para la orquestación segura de nodos de auditoría distribuidos

Agustín Javier Di Bartolo, Mohammadhossein Homaei, Alberto López, Andrés Caro, Mar Ávila

Grupo de Ingeniería de Medios

Universidad de Extremadura

adibartolo@unex.es, mhomaein@alumnos.unex.es, {albertolt, andresc, mmavila}@unex.es

Resumen—Las plataformas de comando y control (C2) se han desarrollado tradicionalmente en contextos ofensivos, lo que ha condicionado su percepción y ha limitado su adopción en entornos académicos y organizativos donde se priorizan la transparencia y la gobernanza. En este trabajo se presenta el diseño de una arquitectura de C2 basada en roles, orientada a la orquestación segura de nodos de auditoría distribuidos. La propuesta adopta un modelo SaaS multi-tenant e integra mecanismos de gestión de identidad, control de acceso basado en roles y segmentación interna de servicios, junto con capacidades de automatización y persistencia estructurada de datos. La arquitectura define una separación explícita entre el plano de acceso, la lógica de control y el entorno de ejecución en los nodos, evitando la exposición directa de estos a redes externas. Finalmente, se describe la validación funcional de la arquitectura en un entorno de pruebas controlado, con el objetivo de establecer un marco reproducible para la gestión segura de auditorías distribuidas.

Index Terms—Comando y Control, C2, Red Team, Automatización, RBAC.

Tipo de contribución: *Investigación en desarrollo*

I. INTRODUCCIÓN

La proliferación de dispositivos de auditoría desplegados en infraestructuras distribuidas y heterogéneas [1] ha incrementado la complejidad operativa y la necesidad de esquemas de coordinación centralizada capaces de garantizar supervisión estructurada, persistencia de eventos y control coherente entre nodos distribuidos. La administración aislada de estos dispositivos mediante accesos remotos o scripts independientes, como en enfoques previos [2], [3], resulta insuficiente cuando se requiere orquestación automatizada, almacenamiento trazable de resultados y diferenciación formal entre usuarios y organizaciones.

Los sistemas de C2 historicamente han sido estudiados desde la óptica del malware, botnets y redes comprometidas, lo que ha condicionado su análisis casi exclusivamente al ámbito de la actividad adversaria [4]. Diversos trabajos han demostrado que las arquitecturas C2 constituyen también un componente estructural en la modelización de sistemas complejos, donde cumplen funciones de coordinación, emisión de órdenes y control de ejecución dentro de entornos distribuidos [5], [6]. Desde esta perspectiva, un sistema C2 puede concebirse como un mecanismo legítimo de orquestación y supervisión cuando su diseño y uso se enmarcan en contextos controlados.

En entornos de auditoría y experimentación en seguridad, una plataforma C2 puede emplearse para coordinar dispositi-

vos autorizados, ejecutar tareas de evaluación de manera estructurada y mantener trazabilidad de las acciones realizadas.

A pesar de este potencial, las soluciones actualmente disponibles presentan limitaciones significativas. Por un lado, las plataformas comerciales suelen operar bajo modelos propietarios que dificultan la auditoría independiente del código y restringen su adopción en entornos académicos o de investigación. Por otro, numerosas herramientas de código abierto están concebidas principalmente para escenarios ofensivos o de emulación adversaria, priorizando el sigilo y la evasión sobre la transparencia y la gobernanza multiusuario. Asimismo, los desarrollos académicos existentes tienden a centrarse en la validación conceptual o en la automatización de campañas de ataque, sin abordar de forma integral aspectos como el aislamiento multi-tenant, la persistencia estructurada de resultados o la gestión basada en roles.

La motivación de este trabajo surge a partir de las limitaciones observadas en un proyecto previo de auditoría de seguridad [7], en el que la plataforma C2 utilizada [8] no permitía la coordinación estructurada de múltiples dispositivos ni la gestión diferenciada de usuarios y organizaciones. Esta carencia evidenció la necesidad de definir una arquitectura orientada explícitamente a la orquestación segura de nodos de auditoría distribuidos, incorporando control de acceso basado en roles, separación lógica entre organizaciones y persistencia centralizada de la información generada.

En este contexto, la principal aportación de este trabajo es definir la arquitectura de una plataforma de C2 en roles, concebida bajo un modelo SaaS y orientada a entornos confiables. La propuesta se fundamenta en el uso de componentes de código abierto, segmentación de servicios, gestión centralizada de identidad y ejecución aislada en los nodos de auditoría. El aporte se centra en definir la arquitectura y tecnologías para su validación preliminar en un entorno de pruebas controlado.

El resto del artículo se organiza de la siguiente manera. La Sección II revisa el estado del arte y clasifica las plataformas C2 existentes según su contexto operativo. La Sección III describe la arquitectura propuesta y sus componentes principales. En la Sección IV discutimos los resultados obtenidos. Finalmente, la Sección V presenta las conclusiones y las líneas de trabajo futuro.

II. TRABAJOS RELACIONADOS

Las plataformas de C2 suelen confundirse con mecanismos básicos de acceso remoto, como el uso de una consola o la ejecución manual de comandos sobre una conexión de red. Sin embargo, mientras que el acceso remoto permite interactuar con un sistema de forma puntual, una arquitectura C2 incorpora una capa adicional de control que posibilita la coordinación de tareas, la gestión de estado, la automatización y la visibilidad centralizada sobre múltiples dispositivos. Esta distinción resulta especialmente relevante en entornos distribuidos donde se requiere escalabilidad, trazabilidad y repetibilidad más allá del control punto a punto.

En la práctica, las soluciones C2 han evolucionado para responder a distintos contextos operativos y perfiles de usuario. De forma general, pueden agruparse en tres categorías principales:

- **Plataformas C2 comerciales**
- **Plataformas C2 de código abierto**
- **Plataformas C2 orientados a investigación**

Cada una de estas responde a objetivos distintos y presenta fortalezas y limitaciones específicas. Las subsecciones siguientes analizan estas tres categorías con el fin de identificar el enfoque principal y las carencias existentes a cubrir por este trabajo.

II-A. Plataformas C2 comerciales

Las soluciones comerciales de C2 son ampliamente empleadas por grandes organizaciones y proveedores de servicios de seguridad debido a su madurez funcional. Suelen ofrecer interfaces centralizadas, gestión avanzada de sesiones, soporte colaborativo y capacidades integradas para simulación de adversarios.

Entre las plataformas comerciales más representativas se encuentra:

- **Cobalt Strike:** orientada a simulación adversaria profesional, con soporte colaborativo y gestión avanzada de sesiones [9]. En la Figura 1 se observa la interface gráfica de la herramienta para su uso.




Figura 1. Plataforma Cobalt Strike

No obstante, estas plataformas se distribuyen habitualmente bajo modelos de licenciamiento restrictivos y esquemas de suscripción que limitan su adopción en pequeñas y medianas

organizaciones o entornos académicos. Además, su naturaleza cerrada dificulta la verificación independiente del código y de los mecanismos internos de control, lo que puede resultar problemático en contextos donde se exige transparencia y auditabilidad.

II-B. Plataformas C2 de código abierto

Las herramientas C2 de código abierto constituyen una alternativa accesible para equipos que no disponen de recursos para desarrollar infraestructuras propias. Estas plataformas suelen ofrecer comunicaciones cifradas, gestión de sesiones y ejecución modular de comandos sobre sistemas distribuidos.

La Tabla I resume algunas de las plataformas C2 de código abierto más representativas y sus principales enfoques. La selección se basa en su adopción dentro de la comunidad de seguridad y en la diversidad de arquitectura y lenguaje utilizados.

Tabla I
PLATAFORMAS C2 DE CÓDIGO ABIERTO REPRESENTATIVAS

Plataforma	Enfoque principal	Ref.
Havoc	Framework moderno orientado a red teaming con arquitectura modular y comunicaciones cifradas.	[10]
Pupy	Herramienta de post-explotación multiplataforma con ejecución en memoria y extensibilidad en Python.	[11]
Empire	Framework maduro de automatización ofensiva basado en PowerShell.	[12]
Merlin	C2 experimental que emplea HTTP/2 cifrado como canal de comunicación.	[13]
Sliver	Framework ligero escrito en Go para red team y pruebas de penetración.	[14]

Sin embargo, la mayoría de estas soluciones están diseñadas con una orientación eminentemente ofensiva, priorizando la evasión, el sigilo y escenarios de corta duración. En consecuencia, suelen carecer de mecanismos formales de gobernanza multiusuario, aislamiento multi-tenant o gestión persistente de tareas, aspectos relevantes en entornos confiables y de uso prolongado.

II-C. Plataformas C2 orientados a investigación

Diversos trabajos académicos han propuesto marcos C2 con fines experimentales, centrados en la emulación de adversarios o en la validación de conceptos.

Tabla II
FRAMEWORKS C2 ORIENTADOS A INVESTIGACIÓN

Trabajo	Enfoque principal	Ref.
Buzzard	Arquitectura C2 descentralizada basada en túneles cifrados para mejorar resiliencia y reducir latencia del canal de mando.	[15]
MEPHISTO	Marco estructurado para emulación adversaria y ejecución coordinada de campañas de ataque en entornos controlados.	[16]
Temperance	Automatización de flujos de emulación ofensiva con enfoque en repetibilidad experimental.	[17]
DeepRed	Integración de técnicas de aprendizaje automático en el plano de control para coordinación inteligente de tareas.	[18]
Botnet	Análisis fundacional de arquitecturas C2 centralizadas, descentralizadas y P2P.	[19]

Con el fin de contextualizar los desarrollos académicos más relevantes en este ámbito, la Tabla II presenta una síntesis de propuestas orientadas a investigación, destacando su enfoque principal dentro del plano de mando y control.

Si bien estas propuestas contribuyen significativamente al avance conceptual del estado del arte, suelen materializarse como prototipos o sistemas de prueba de concepto. En consecuencia, rara vez contemplan aspectos como la gobernanza multiusuario, el aislamiento entre organizaciones o la orquestación persistente en nodos de auditoría con recursos limitados.

II-D. Retos abiertos y brechas identificadas

A partir del análisis realizado en las secciones anteriores, se identifican limitaciones recurrentes en los distintos enfoques de comando y control existentes.

El análisis comparativo realizado permite identificar varias carencias recurrentes en las soluciones existentes:

- **Cobertura limitada del ciclo de vida:** la mayoría de plataformas se centran en fases de post-explotación y no contemplan la coordinación estructurada de etapas previas como reconocimiento o validación inicial.
- **Ausencia de gobernanza multiusuario:** pocas soluciones integran control de acceso basado en roles o separación formal entre organizaciones.
- **Escasa orientación a entornos confiables:** predominan diseños orientados a la evasión frente a arquitecturas pensadas para auditoría estructurada.
- **Automatización insuficiente:** la programación sistemática de tareas y la orquestación persistente no suelen formar parte del diseño base.
- **Falta de uso de IA:** no se encontraron herramientas que se integren con modelos de IA para mejorar contextos o solicitar ayuda en los procesos a seguir.

Tabla III
LIMITACIONES IDENTIFICADAS EN ENFOQUES C2 EXISTENTES

Enfoque	Limitaciones clave
Plataformas C2 comerciales	Alto coste de licenciamiento, naturaleza cerrada y limitada transparencia para auditoría independiente.
Plataformas C2 de código abierto	Fuerte orientación ofensiva, escasa gobernanza multiusuario y diseño pensado para campañas de corta duración.
Frameworks C2 académicos	Implementaciones de tipo prototipo, con limitada madurez para despliegues prolongados y gestión multi-tenant.

La Tabla III resume las principales carencias observadas. Estas brechas justifican la necesidad de definir una arquitectura C2 estructurada, transparente y orientada a la orquestación controlada de dispositivos distribuidos, cuyo diseño se presenta en la sección siguiente.

III. ARQUITECTURA PROPUESTA

La plataforma de C2 propuesta se implementa bajo un modelo Software-as-a-Service (SaaS), donde la infraestructura central de control se encuentra desplegada en la nube. Este enfoque permite centralizar la gestión, la orquestación y el almacenamiento de datos, reduciendo la complejidad de despliegue en las organizaciones y facilitando la escalabilidad y el mantenimiento continuo de la plataforma.

La arquitectura se organiza en cinco etapas funcionales que estructuran el flujo completo desde el acceso del usuario hasta la ejecución de tareas en los dispositivos edge distribuidos. Este enfoque modular permite separar responsabilidades, reforzar el aislamiento entre componentes y facilitar la escalabilidad del sistema.



Figura 2. Arquitectura C2

La Figura 2 presenta una vista global del modelo arquitectónico propuesto. A continuación, se presenta un análisis detallado de cada etapa funcional de la arquitectura, incluyendo las tecnologías seleccionadas y la justificación de su incorporación desde una perspectiva técnica y de diseño de sistemas.

III-A. Gestión de Acceso y Roles

La primera etapa de la arquitectura corresponde a la gestión de acceso y control de usuarios. Se implementa un modelo de control de acceso basado en roles (RBAC) [20], diseñado para garantizar una separación clara de responsabilidades y limitar el alcance de las acciones disponibles para cada tipo de usuario a los dispositivos edge [21].

El sistema soporta múltiples usuarios distribuidos en diferentes organizaciones, bajo un esquema multi-tenant que asegura el aislamiento lógico entre clientes. Cada usuario se asocia a un tenant específico y sus permisos se delimitan estrictamente dentro de ese contexto, impidiendo cualquier visibilidad o interacción con recursos pertenecientes a otras organizaciones.



Figura 3. Usuarios y Roles

Como se puede apreciar en la Figura 3 se definen tres roles principales dentro de la plataforma:

- **Administrador:** dispone de privilegios ampliados sobre la configuración del sistema, gestión de tenants, alta y baja de usuarios, y supervisión de parámetros críticos de la plataforma. Este rol tiene acceso a funciones de mantenimiento y control estructural del sistema.

- **Operador:** es responsable de la ejecución y configuración de tareas de auditoría. Puede lanzar acciones manuales, definir parámetros de módulos habilitados y programar tareas recurrentes, pero no posee acceso a configuraciones globales ni a la administración de otros tenants.
- **Solo lectura:** orientado a perfiles no técnicos o de supervisión. Este rol permite visualizar dashboards, resultados históricos y métricas agregadas, sin capacidad para ejecutar tareas ni modificar configuraciones.

La validación de identidad y asignación de permisos se realiza mediante un servicio externo de gestión de identidad integrado con el backend de la plataforma. El backend actúa como punto de decisión de autorización, verificando los permisos asociados al token de sesión antes de permitir cualquier operación.

Este enfoque basado en RBAC no solo mejora la seguridad del sistema, sino que también facilita la colaboración entre perfiles técnicos y de gestión, permitiendo que distintos niveles organizativos interactúen con la plataforma de manera controlada y auditada.

III-B. Validación, autenticación y visualización

Otra de las capas estructurales de la arquitectura propuesta es la gestión de identidad y control de acceso, implementada mediante un sistema de *Identity and Access Management* (IAM). Este tipo de solución centraliza los procesos de autenticación, la emisión de credenciales temporales y la aplicación de políticas de autorización, asegurando que cada usuario acceda únicamente a los recursos y funcionalidades que le corresponden de acuerdo con su rol y su pertenencia organizacional [22].

En la arquitectura planteada, el servicio de IAM se implementa mediante **Keycloak**, una solución opensource de IAM [23], desplegado como componente independiente dentro del entorno en la nube. Esta separación permite desacoplar la gestión de credenciales del núcleo lógico del sistema, facilitando la aplicación de políticas de seguridad, la gestión de sesiones y la integración con esquemas de control de acceso basado en roles.

La capa de presentación (frontend) se desarrolla utilizando **Antigravity**, un framework basado en Python que permite construir interfaces web de manera ágil y estructurada [24]. Esta elección favorece la coherencia tecnológica del ecosistema y simplifica su mantenimiento.

Por su parte, el backend se implementa mediante **FastAPI** [25], un framework moderno para el desarrollo de APIs en Python que destaca por su rendimiento, validación automática de datos y compatibilidad con estándares actuales. FastAPI actúa como plano de control lógico del sistema, gestionando las solicitudes provenientes del frontend, validando los tokens emitidos por el IAM y aplicando las políticas de autorización correspondientes.

La interacción entre los componentes se ilustra en la Figura 4 y puede sintetizarse en cuatro fases:

- **(1) Autenticación.** El usuario accede al *frontend* (Antigravity), que delega la autenticación en **Keycloak**. El servidor IAM valida credenciales conforme a las políticas definidas.




Figura 4. Procesos de autenticación

- **(2) Emisión de credenciales.** Tras validación exitosa, Keycloak genera un *JSON Web Token* (JWT) firmado digitalmente, que incluye identidad, rol y *tenant*. El token actúa como credencial temporal de acceso.
- **(3) Validación y autorización.** El *backend* (FastAPI) verifica la firma, vigencia y atributos del JWT. En esta etapa se aplica el modelo RBAC, diferenciando autenticación (quién es) de autorización (qué puede hacer).
- **(4) Acceso controlado.** Una vez autorizado, el backend habilita el acceso a los servicios internos. Las respuestas se presentan en el *frontend*, restringidas estrictamente por rol y *tenant*.

La integración entre Keycloak, Antigravity y FastAPI permite implementar un modelo multiusuario y multi-tenant alineado con los principios de mínimo privilegio, separación de responsabilidades y control centralizado de acceso. Este enfoque refuerza la seguridad del sistema al desacoplar la gestión de identidades del núcleo lógico de la aplicación y garantizar que cada usuario visualice únicamente la información correspondiente a su organización.

El modelo multi-tenant se implementa de manera coordinada entre la capa de identidad y el plano de control lógico. El servidor IAM incorpora la pertenencia del usuario a un tenant dentro del token de autenticación emitido. Sin embargo, el aislamiento efectivo se aplica en el backend, donde cada solicitud es procesada en función del identificador de tenant contenido en el token, ejemplo:

```

{
  "sub": "user_id",
  "role": "operator",
  "tenant_id": "org_02"
}
  
```

III-C. Orquestación y Persistencia de Datos

La orquestación se implementa mediante un motor de automatización integrado en el plano de control, el cual interactúa con el backend. Cuando un operador inicia una tarea, ya sea manualmente o mediante programación periódica, el backend valida los permisos del usuario y delega la ejecución al motor de automatización. Este motor gestiona la secuencia de acciones, la comunicación con los dispositivos edge y la recepción de resultados.




Figura 5. Flujo de orquestación y persistencia de tareas

El flujo representado en la Figura 5 describe el ciclo completo de ejecución y almacenamiento de tareas dentro de la arquitectura propuesta:

- **(1) Registro inicial:** El motor de orquestación genera una instancia asociada a la tarea solicitada y registra su creación en la capa de persistencia.
- **(2) Coordinación de ejecución:** La tarea es procesada por el motor de orquestación, que valida parámetros, gestiona el estado y coordina su ejecución hacia el dispositivo correspondiente.
- **(3) Persistencia de resultados:** Una vez finalizada la ejecución, los resultados y metadatos asociados (estado, marca temporal y tenant) son almacenados en la base de datos.
- **(4) Confirmación y cierre de ciclo:** El estado actualizado de la tarea es devuelto al motor de orquestación, permitiendo completar el ciclo y notificar al plano de control.

El modelo de ejecución soporta tanto tareas bajo demanda como tareas programadas, esto permite automatizar rutinas de seguridad repetitivas sin requerir intervención constante del operador, garantizando consistencia y trazabilidad en el tiempo.

La orquestación constituye el núcleo operativo de la plataforma, permitiendo coordinar la ejecución estructurada de tareas de auditoría sobre dispositivos distribuidos [26]. A diferencia de modelos tradicionales de ejecución puntual, incorporamos una capa de automatización, utilizando N8N [27], que formaliza la secuencia de acciones mediante flujos de trabajo definidos como *playbooks*, como se puede observar en la Figura 6.



Figura 6. Ejemplo de playbook

En cuanto a la persistencia de datos, todas las definiciones de tareas, ejecuciones, resultados y registros de actividad son almacenados en una base de datos relacional centralizada, para la cual utilizamos PostgreSQL, un potente sistema de base de datos relacional de objetos de código abierto con una sólida reputación por su confiabilidad, solidez de funciones y

rendimiento. [28]. Como se puede observar en la Figura 7 cada registro se asocia explícitamente a un *tenant_id*, asegurando el aislamiento lógico entre organizaciones. Este diseño permite realizar análisis históricos, generar reportes y mantener un registro auditable de las actividades realizadas.




Figura 7. Almacenamiento Base de Datos por Tenant

La separación entre orquestación y ejecución efectiva permite que los dispositivos edge se mantengan ligeros, delegando la lógica de coordinación y almacenamiento al plano de control en la nube. De esta manera, la arquitectura favorece la escalabilidad horizontal y la operación prolongada en entornos con recursos limitados.

En conjunto, la integración entre backend, motor de automatización y base de datos persistente extiende el modelo tradicional de comando y control hacia un esquema de orquestación estructurada, con soporte para multiusuario, multi-tenant y ejecución repetible de tareas.

III-D. Modelo de Conectividad Segura

La conectividad segura constituye un componente esencial de la arquitectura propuesta, ya que garantiza la comunicación protegida entre el plano de control desplegado en la nube y los dispositivos distribuidos en entornos cliente. Dado que la plataforma opera bajo un modelo SaaS, todos los componentes centrales residen en un entorno cloud controlado, mientras que los dispositivos edge se encuentran en redes externas potencialmente heterogéneas.



Figura 8. Modelo de comunicación segura

Como se puede observar en la Figura 8 se incorpora un *Web Application Firewall* (WAF) como primera capa de defensa entre los usuarios externos y el frontend del sistema.

El WAF permite mitigar ataques dirigidos a la capa de aplicación, tales como inyección SQL, *Cross-Site Scripting* (XSS), intentos de fuerza bruta y patrones de tráfico anómalos [29]. Esta protección cubre tanto el acceso al panel web como las solicitudes hacia la API del backend, reduciendo la superficie de ataque pública y reforzando los mecanismos internos de autenticación y autorización.

En cuanto a la comunicación con los edge devices, utilizamos un modelo de comunicación basado en túneles cifrados

iniciados de forma saliente desde los dispositivos edge hacia la infraestructura central. Este enfoque evita la necesidad de exponer servicios entrantes, reduciendo significativamente la superficie de ataque y facilitando la integración en entornos protegidos por firewalls o mecanismos de traducción de direcciones (NAT) [30].

Todas las comunicaciones entre el backend y los dispositivos edge se realizan mediante peticiones HTTPS transmitidas a través del túnel seguro. El backend envía solicitudes autenticadas utilizando métodos estándar como POST y GET, mientras que los dispositivos responden mediante mecanismos basados en webhooks. En la Tabla IV se muestran unos ejemplos sencillos de la solicitud y los resultados devueltos:

Tabla IV
REPRESENTATIVE EDGE DEVICE API ENDPOINTS

Request	Method	Response (JSON Structure)
https://device-01.mydomain.es/health	GET	{ "status": "OK" }
https://device-01.mydomain.es/arp_scan	POST	{ "hosts": [{ "ip": "...", "mac": "...", "vendor": "..."}], "execution_time": "..." }

Este modelo permite una interacción asíncrona y desacoplada, en la que la ejecución de tareas y el envío de resultados no dependen de una conexión interactiva persistente.

Adicionalmente, como se observa en la Figura 9 la infraestructura en la nube implementa segmentación de red a nivel de contenedores, aislando frontend, backend, motor de automatización y base de datos en redes internas diferenciadas. Esta segmentación limita movimientos laterales y refuerza el principio de mínimo privilegio dentro del propio plano de control [31]




Figura 9. Segmentación de redes de contenedores

El aislamiento multi-tenant se mantiene también en la capa de conectividad. Cada dispositivo edge se asocia explícitamente a un único *tenant*, y las peticiones emitidas por el backend incluyen información contextual validada previamente mediante el sistema de identidad. De esta forma, se evita cualquier posibilidad de interacción cruzada entre organizaciones.

III-E. Entorno de Ejecución en Dispositivos Edge

El entorno de ejecución en dispositivos Edge constituye la capa distribuida encargada de recibir y ejecutar las órdenes emitidas por el automatizador. A diferencia de los modelos

tradicionales basados en implantes persistentes o agentes con privilegios elevados, la arquitectura propuesta adopta un enfoque de ejecución aislada y bajo demanda.




Figura 10. Arquitectura Edge Device

El nodo de auditoría, esta formado por dos contenedores claves, uno que permite la comunicación segura (túnel) y el otro ejecuta Flask un microframework web escrito en Python que permite crear aplicaciones web y APIs de forma ligera y flexible [32], el cual orquesta las solicitudes recibidas, como se puede observar en la Figura 10.

Por otro lado, existen imágenes de contenedores que se encuentran disponibles para desplegar en el momento de la ejecución de una tarea desde Flask. La Figura 11 muestra un ejemplo del código ejecutado por Flask para recibir y ejecutar las tareas:

```
from flask import Flask, request, jsonify
import subprocess

app = Flask(__name__)

@app.route("/health", methods=["GET"])
def health():
    return jsonify({"status": "ok"}), 200

@app.route("/scan/arp", methods=["POST"])
def scan_arp():
    cmd = f"docker run --rm audit-tools arp-scan"
    result = subprocess.run(cmd, shell=True, capture_output=True, text=True)
    return jsonify({"output": result.stdout}), 200

if __name__ == "__main__":
    app.run(host="0.0.0.0", port=5000)
```

Figura 11. Código Flask

Cuando el backend envía una orden válida a través del túnel seguro, el agente realiza las siguientes acciones:

1. Valida la estructura y autenticidad de la solicitud recibida.
2. Instancia dinámicamente un contenedor efímero asociado a la tarea solicitada.
3. Inyecta los parámetros necesarios como variables de entorno o argumentos controlados.
4. Supervisa la ejecución y captura la salida estructurada.
5. Destruye el contenedor una vez finalizada la tarea.

Desde la perspectiva de seguridad, esta aproximación reduce significativamente la superficie de ataque del dispositivo Edge, ya que:

- No se instalan herramientas de auditoría directamente en el sistema operativo anfitrión.
- No existen servicios expuestos hacia la red local del cliente.
- Las dependencias se encuentran encapsuladas dentro de cada imagen de contenedor.

- Las ejecuciones no mantienen sesiones persistentes.

Este modelo simplifica el mantenimiento del nodo y permite actualizar herramientas o modificar comportamientos sin intervenir directamente en el entorno del cliente.

Finalmente, cada dispositivo implementa un mecanismo de verificación periódica de disponibilidad (*heartbeat*), mediante el cual informa de su estado operativo al plano de control. Esta señal permite detectar fallos de conectividad, interrupciones del túnel seguro o problemas locales de ejecución, reforzando la capacidad de supervisión centralizada.

IV. RESULTADOS

IV-A. Validación arquitectónica en entorno de pruebas

La arquitectura propuesta fue desplegada en un entorno controlado que reproduce el modelo SaaS definido en la Sección III, con el propósito de verificar la consistencia funcional del diseño, la correcta segmentación lógica entre componentes y la interacción segura entre sus distintas capas. La evaluación se orientó a validar los principios estructurales de la arquitectura —aislamiento multi-tenant, control de acceso basado en roles, orquestación automatizada y ejecución segura en nodos de auditoría— más que a medir rendimiento extremo.

Para la validación se utilizaron dos nodos de auditoría desplegados en organizaciones distintas: una Raspberry Pi operando como dispositivo dedicado de auditoría y una máquina virtual en una infraestructura independiente. Esta heterogeneidad permitió comprobar la estabilidad del modelo en contextos operativos diferenciados.

La Tabla V resume las pruebas realizadas para verificar el aislamiento multi-tenant.

Tabla V
VALIDACIÓN DE AISLAMIENTO MULTI-TENANT

Métrica	Ejecuciones	Incidentes
Creación/lectura de datos cruzados	40	0
Separación de logs por tenant	40	0
Aislamiento de visualización	40	0

Los resultados confirman la ausencia total de contaminación de datos entre organizaciones. No se registraron accesos cruzados ni exposición de información fuera del ámbito del tenant correspondiente. Asimismo, el modelo RBAC operó correctamente, restringiendo las operaciones según el rol asignado y garantizando que cada usuario accediera únicamente a los recursos autorizados. La autenticación mediante el servidor IAM, la emisión de tokens y su validación en el backend se ejecutaron sin inconsistencias durante las pruebas.

IV-B. Validación del modelo de comunicación segura

El modelo de comunicación se evaluó verificando el establecimiento de túneles cifrados salientes desde los nodos de auditoría hacia el plano de control. En ningún caso fue necesaria la apertura de puertos entrantes en las infraestructuras remotas, reduciendo la superficie de exposición externa.

La Tabla VI presenta la latencia promedio observada entre el plano de control y cada nodo de auditoría.

Aunque se observan diferencias de latencia entre ambos entornos, estas no afectaron de forma significativa la ejecución de tareas, dado que el intercambio de información se limita a

Tabla VI
COMPARACIÓN DE LATENCIA PROMEDIO ENTRE NODOS

Nodo	Latencia (ms)
Nodo A (Raspberry Pi)	28
Nodo B (Máquina virtual)	60

mensajes estructurados en formato JSON y no a transferencias masivas de datos. Durante las pruebas no se detectaron accesos directos entre tenants, ni exposición de servicios administrativos fuera del canal autenticado. Los nodos de auditoría no expusieron servicios entrantes accesibles desde Internet.

IV-C. Orquestación y persistencia de datos

Se evaluó la capacidad de orquestación automática mediante la ejecución repetida de dos tareas representativas: descubrimiento ARP y enumeración de puertos y servicios. Cada tarea fue ejecutada veinte veces por nodo, totalizando cuarenta ejecuciones por tipo de operación. Todas las ejecuciones fueron programadas automáticamente mediante playbooks, sin intervención manual.

La Tabla VII resume los resultados obtenidos.

Tabla VII
RESULTADOS DE REPETIBILIDAD EN DOS NODOS DE AUDITORÍA

Tarea	Ejecuciones	Éxito	Fallos
Host IP and ARP Discovery (T1595.001)	40	38 (95 %)	2 (5 %)
Port and Service Enumeration (T1595.002)	40	37 (92.5 %)	3 (7.5 %)

Las tasas de éxito superiores al 92 % evidencian estabilidad operativa en ambos entornos. Los fallos observados no estuvieron asociados a errores estructurales del modelo de orquestación, sino a condiciones externas puntuales, cuya distribución se muestra en la Tabla VIII.

Tabla VIII
CLASIFICACIÓN DE FALLOS OBSERVADOS

Tipo de error	Cantidad	Porcentaje
Error en webpanel	0	0 %
Error en VPS	2	40 %
Fallo de túnel seguro	1	20 %
Conectividad nodo externo	2	40 %
Error ejecución contenedor	0	0 %
Total	5	100 %

La mayoría de los incidentes se vincularon a factores de infraestructura o conectividad externa, especialmente en el nodo remoto. No se registraron fallos derivados del modelo de aislamiento de contenedores ni del mecanismo de autenticación.

En conjunto, los resultados validan que la arquitectura soporta ejecución repetible, aislamiento consistente entre organizaciones y almacenamiento persistente de resultados, manteniendo trazabilidad completa de cada operación. Ello confirma el cumplimiento de los principios de auditabilidad, control y segmentación definidos en el diseño arquitectónico.

V. CONCLUSIONES Y TRABAJO FUTURO

Este trabajo ha definido y validado preliminarmente una arquitectura de C2 orientada a la orquestación segura de nodos de auditoría en entornos confiables. La propuesta prioriza

transparencia, gobernanza multiusuario, aislamiento multi-tenant y persistencia estructurada de información.

El modelo SaaS permite centralizar la coordinación de tareas sin exponer directamente los nodos, reduciendo la superficie de ataque. La segmentación interna, la autenticación basada en tokens y la ejecución temporal mediante contenedores refuerzan el principio de mínimo privilegio.

Las pruebas en dos entornos heterogéneos confirmaron la viabilidad técnica del diseño, verificando aislamiento entre organizaciones, aplicación correcta del modelo RBAC y estabilidad del mecanismo de orquestación. Los fallos observados se asociaron a condiciones externas de infraestructura, sin evidenciar inconsistencias arquitectónicas.

Como trabajo futuro se plantea:

- Evaluar el comportamiento bajo mayor concurrencia.
- Incorporar métricas formales de rendimiento y disponibilidad.
- Analizar la escalabilidad horizontal del plano de control.
- Integrar capacidades de análisis asistido por IA en la automatización.

AGRADECIMIENTOS

Este trabajo actividad ha sido cofinanciado al 85 % por la Unión Europea, Fondo Europeo de Desarrollo Regional, y la Junta de Extremadura. Autoridad de Gestión: Ministerio de Hacienda, Ayuda GR24170.

REFERENCIAS

- [1] W. Shi, J. Cao, Q. Zhang, Y. Li, and L. Xu, "Edge computing: Vision and challenges," *IEEE Internet of Things Journal*, vol. 3, no. 5, pp. 637–646, 2016.
- [2] N. B. Al Barghuthi, M. Saleh, S. Alsuwaidi, and S. Alhammadi, "Evaluation of portable penetration testing on smart cities applications using raspberry pi iii," in *Proceedings of the 2017 Fourth HCT Information Technology Trends (ITT)*, 2017, pp. 67–72.
- [3] M. Homaei, O. Mogollón-Gutiérrez, J. C. Sancho, M. Ávila, and A. Caro, "A review of digital twins and their application in cybersecurity based on artificial intelligence," *Artificial Intelligence Review*, vol. 57, no. 8, Jul. 2024.
- [4] T. A. Tuan, H. V. Long, L. H. Son *et al.*, "Performance evaluation of botnet ddos attack detection using machine learning," *Evolutionary Intelligence*, vol. 13, pp. 283–294, 2020.
- [5] F. Wang, L. Guo, X. Wang, H. Wu, Y. Yu, C. Duan, Y. Lv, Y. Hao, Z. Lin, L. Wei, Y. Xiao, and B. Xia, "Study of system-of-systems modeling approaches for command and control models," in *Intelligent Simulation*, Y. Liu, N. Li, X. Song, and Y. Guo, Eds. Singapore: Springer Nature Singapore, 2026, pp. 91–100.
- [6] M. Homaei, M. Tarif, P. Rodriguez, A. Caro Lindo, and M. Ávila, "Causal digital twins for cyber-physical security in water systems: A framework for robust anomaly detection," *Machine Learning with Applications*, 2026.
- [7] A. J. Di Bartolo, M. Homaei, B. Abbou, F. J. Muñoz Ruiz, and M. Ávila Vegas, "Red-pi: An adversary for the water sector," in *Proceedings of the International Conference on Artificial Intelligence (ICAI 2025)*, Universidade da Beira Interior, Portugal, 2025, p. 62, https://icai2025.ubi.pt/Proceedings_ICAI_2025.pdf.
- [8] 4m3r0r, "Telec2: Command-and-control framework based on telegram," <https://github.com/4m3r0r/TeleC2>, 2026, accessed 2026.
- [9] K. Alharthi, "Analysis and exploitation of active directory vulnerabilities using cobalt strike: A practical approach," https://doi.org/10.1007/978-3-031-88874-8_29, 2026, accessed 2026.
- [10] Havoc Framework, "Havoc: Open-source command-and-control framework," <https://github.com/HavocFramework/Havoc>, 2026, accessed 2026.
- [11] Pupy Project, "Pupy: Cross-platform post-exploitation tool," <https://github.com/n1nj4sec/pupy>, 2026, accessed 2026.
- [12] BC-Security, "Empire: Powershell post-exploitation framework," <https://github.com/BC-SECURITY/Empire>, 2026, accessed 2026.
- [13] Ne0nd0g, "Merlin: Http2-based command-and-control framework," <https://github.com/Ne0nd0g/merlin>, 2026, accessed 2026.
- [14] Bishop Fox, "Sliver: Open-source adversary emulation framework," <https://github.com/BishopFox/sliver>, 2026, accessed 2026.
- [15] A. Hariharan, A. Arun Kumar, G. Rajendran, N. Srinivasan, P. K. Sridhar, and K. K. Perumalsamy, "A novel post exploitation framework for red team operations – buzzard," in *Proceedings of the 2024 International Conference on Intelligent Systems for Cybersecurity (ISCS)*. IEEE, 2024, pp. 1–5.
- [16] A. Author *et al.*, "Mephisto: A red team tool for offensive security," in *ICCP*. IEEE, 2024.
- [17] —, "Temperance: An adversary emulation framework," in *IEEE Conference on Cybersecurity*. IEEE, 2025.
- [18] —, "Deepred: A deep learning-powered command and control system," *To Be Added*, 2025, DOI to be added.
- [19] H. R. Zeidanloo and A. Abdul Manaf, "Botnet command and control mechanisms," in *Proceedings of the Second International Conference on Computer and Electrical Engineering (ICCEE)*, vol. 1. IEEE, 2009, pp. 564–568.
- [20] G. Zou, J. Wang, D. Huang, and L. Jiang, "Model design of role-based access control and methods of data security," in *Proceedings of the 2010 International Conference on Web Information Systems and Mining (WISM)*, vol. 1, 2010, pp. 167–170.
- [21] S. Bhatt, T. K. Pham, M. Gupta, J. O. Benson, J. Park, and R. S. Sandhu, "Attribute-based access control for aws internet of things and secure industries of the future," *IEEE Access*, vol. 9, pp. 107 200–107 223, 2021.
- [22] T. Norimatsu, Y. Nakamura, and T. Yamauchi, "Policy-based method for applying oauth 2.0-based security profiles," *IEICE Transactions on Information and Systems*, vol. E106-D, no. 9, pp. 1364–1379, 2023.
- [23] Keycloak, "Keycloak: Open source identity and access management," <https://www.keycloak.org/>, 2026, accessed 2026.
- [24] AntigraVity, "Antigravity python framework," <https://antigravity.google/>, 2026, accessed 2026.
- [25] FastAPI, "Fastapi: High performance, easy to learn, fast to code, ready for production," <https://fastapi.tiangolo.com/>, 2026, accessed 2026.
- [26] O. Sapsai, Y. Martseniuk, and A. Partyka, "Automate cloud security incident management with a soar-based approach," <https://api.semanticscholar.org/CorpusID:283160179>, 2025.
- [27] n8n GmbH, "n8n: Workflow automation tool," <https://n8n.io/>, 2026, accessed 2026.
- [28] PostgreSQL Global Development Group, "Postgresql: The world's most advanced open source relational database," <https://www.postgresql.org/>, 2026.
- [29] R. A. Muzaki, O. C. Briliyant, M. A. Hasditama, and H. Ritchi, "Improving security of web-based application using modsecurity and reverse proxy in web application firewall," *Proceedings of the 2020 International Workshop on Big Data and Information Security (IWBIS)*, pp. 85–90, 2020.
- [30] Cloudflare, "Cloudflare tunnel – securely connect applications to cloudflare," <https://developers.cloudflare.com/cloudflare-one/networks/connectors/cloudflare-tunnel/>, 2026, accessed 2026.
- [31] W. Zeng, R. Fan, Z. Wang, Y. Xiao, R. Huang, and M. Liu, "Research on docker container network isolation and security management for multi-tenant environments," in *ACM Conference Proceedings*, 2024, pp. 179–185.
- [32] Pallets Projects, "Flask documentation," <https://flask.palletsprojects.com/en/stable/>, 2026, accessed 2026.

Sesión de Investigación 5 - Privacidad

Evaluación de la Lealtad en Apps de Salud: Un Análisis de Discrepancias Mediante Ontologías

Alejandro Pérez-Fuente

Grupo de Investigación en Ingeniería de la Privacidad
Universidad de Valladolid, España
alejandro.perez.fuente@uva.es

Pablo A. Criado-Lozano

Grupo de Investigación en Ingeniería de la Privacidad
Universidad de Valladolid, España
Universidad Europea Miguel de Cervantes, España
pacriado@uemc.es

M. Mercedes Martínez-González

Grupo de Investigación en Ingeniería de la Privacidad
Universidad de Valladolid, España
mercedes@infor.uva.es

Resumen—El ecosistema de aplicaciones de salud móvil (*mHealth*) ha experimentado un crecimiento masivo, convirtiéndose en repositorios críticos de datos personales sensibles. Para facilitar la transparencia y reducir la carga cognitiva del usuario, han surgido las *Privacy Labels* en las tiendas de aplicaciones como resúmenes simplificados de las prácticas de privacidad. Sin embargo, se identifica un vacío en la garantía de fidelidad de estas etiquetas: su efectividad depende de la “lealtad” del desarrollador al declarar sus prácticas frente a lo estipulado en las políticas de privacidad detalladas. Actualmente, se identifica un vacío en el uso de métodos de auditoría basados en ontologías que permitan verificar dicha consistencia de forma trazable y sostenible, superando la opacidad y el coste computacional de las soluciones emergentes basadas en modelos de lenguaje extenso (LLMs). Este trabajo propone un método de análisis de discrepancias fundamentado en los marcos ontológicos DPV y DataSecOnt para evaluar 171 aplicaciones de salud. Los resultados revelan una brecha de lealtad significativa: solo el 60,8 % de las aplicaciones mantienen una coherencia total entre ambas fuentes, detectándose que un 36,8 % de las apps que realmente tratan datos de salud omiten esta declaración en la tienda. Estos hallazgos subrayan la necesidad de auditorías sistemáticas y reproducibles para garantizar el consentimiento informado en el sector de la salud.

Index Terms—Privacy Labels, mHealth, DPV (Data Privacy Vocabulary), Políticas de Privacidad

Tipo de contribución: Investigación original (límite 8 páginas)

I. INTRODUCCIÓN

Los dispositivos móviles se han consolidado como instrumentos esenciales en la vida cotidiana, integrando funciones que van desde la comunicación y la navegación web hasta la gestión de servicios bancarios, redes sociales y agendas personales. Dentro de este ecosistema, las aplicaciones móviles de salud (conocidas como *mHealth*) han experimentado un crecimiento exponencial durante 2025, proyectándose una expansión sostenida para el próximo lustro¹. Esta adopción masiva ha transformado el entorno *mHealth* en vastos repositorios de datos personales de naturaleza sensible, lo que conlleva riesgos críticos para la privacidad ampliamente documentados por marcos normativos como el Reglamento General de Protección de Datos (RGPD) [1].

¹<https://www.fortunebusinessinsights.com/mhealth-apps-market-102020>

Ante la vulnerabilidad de estos datos y para reducir la carga cognitiva de los usuarios al evaluar la privacidad, han surgido mecanismos de transparencia simplificada como las *privacy labels* o secciones de seguridad de los datos en las tiendas de aplicaciones [2]. Sin embargo, la efectividad de estas etiquetas depende de la “lealtad” de los desarrolladores al declarar sus prácticas de recolección. La existencia de discrepancias entre estas etiquetas simplificadas y lo estipulado en las políticas de privacidad detalladas no solo puede comprometer el consentimiento informado, sino que también puede dificultar la auditoría del cumplimiento normativo en un sector tan crítico como el de la salud [3].

Ante la falta de garantías en la transparencia de estas herramientas [4], [5], el presente trabajo se propone evaluar la lealtad de las aplicaciones de salud mediante un método de análisis de discrepancias sostenible, basado en ontologías y trazable para la auditoría de cumplimiento. Para alcanzar este objetivo, el estudio busca dar respuesta a las siguientes preguntas de investigación (PI):

- PI1** ¿Qué volumen de aplicaciones declaran la recopilación de datos de salud en las *Privacy Labels* frente a las menciones detectadas en su Política de Privacidad?
- PI2** ¿Cuál es el porcentaje global de lealtad en el sector *mHealth*, definido como la consistencia total entre lo declarado en las *Privacy Labels* y la Política de Privacidad?
- PI3** ¿En qué medida la fuente de información más accesible para el usuario (las *Privacy Labels*) refleja fielmente el contenido detallado en la Política de Privacidad?
- PI4** ¿En qué medida existe una sobredeclaración de prácticas de privacidad en las *Privacy Labels* respecto a lo estipulado en las Políticas de Privacidad?

Para abordar estas cuestiones, este trabajo aporta un método de análisis de discrepancias caracterizado por su sostenibilidad y trazabilidad. A diferencia de las soluciones emergentes basadas en modelos de lenguaje extenso (LLMs) [6], nuestra propuesta emplea un marco ontológico que garantiza la trazabilidad absoluta de los hallazgos y evita la sobrecarga computacional asociada con la inferencia LLM a gran escala. Este enfoque no solo permite una evaluación precisa de la lealtad en el ecosistema *mHealth*, sino que se posiciona como una herramienta robusta para facilitar la auditoría de cum-

plimiento normativo informado, permitiendo a reguladores y auditores identificar inconsistencias de manera sistemática y reproducible.

El resto de este artículo se estructura de la siguiente manera: la Sección II presenta el estado del arte y el trabajo relacionado en materia de *privacy labels* y políticas de privacidad. La Sección III detalla la metodología propuesta, describiendo desde la obtención de los datos hasta el proceso de análisis y validación mediante marcos ontológicos. En la Sección IV se exponen los resultados obtenidos y su interpretación a través de métricas de confusión. Posteriormente, la Sección V expone la validación del método mediante un análisis manual. Finalmente, la Sección VI presenta las conclusiones alcanzadas y propone futuras líneas de investigación para profundizar en la transparencia del ecosistema *mHealth*.

II. ESTADO DEL ARTE Y TRABAJO RELACIONADO

II-A. Evolución y Limitaciones de las Declaraciones de Privacidad Simplificadas

La literatura reciente ha analizado la coexistencia de las políticas de privacidad extensas con nuevos mecanismos de transparencia simplificada, como las *privacy labels* en las tiendas de aplicaciones. Estos resúmenes visuales se han añadido como una capa adicional para reducir la carga cognitiva del usuario al evaluar la privacidad en el momento de la descarga. Diversos estudios han evaluado la percepción del usuario y la eficacia de estas etiquetas, concluyendo que, si bien reducen la carga cognitiva [2], su utilidad real se ve mermada por la falta de mecanismos de verificación automática que garanticen su veracidad frente al comportamiento real de la aplicación [7]. Esta brecha ha llevado a la comunidad investigadora a realizar análisis comparativos para detectar inconsistencias entre lo declarado en el mercado y las cláusulas legales detalladas, el código fuente, etc. evidenciando que la simplificación informativa a menudo incurre en omisiones críticas sobre la recolección de datos sensibles [8].

II-B. De la Auditoría Manual al Procesamiento Masivo de Políticas de Privacidad

El análisis de las políticas de privacidad ha evolucionado desde revisiones manuales y expertas hacia el uso de técnicas de procesamiento de lenguaje natural para la extracción automática de prácticas de tratamiento [6]. Estudios previos han explorado la consistencia interna de estos documentos legales, señalando que su ambigüedad dificulta el consentimiento informado [9], [10]. Recientemente, el foco se ha desplazado hacia el cruce de estas políticas con otras fuentes de información, como el tráfico de red o las etiquetas de seguridad, para cuantificar su "lealtad" [11], [12]. No obstante, la mayoría de estas aproximaciones dependen de modelos de aprendizaje profundo o modelos de lenguaje extenso (LLMs) que, aunque eficaces en volumen, carecen a menudo de la trazabilidad necesaria para auditorías normativas rigurosas [13], [14].

II-C. Ontologías y Semántica en la Ingeniería de la Privacidad

Como alternativa a la opacidad de los modelos basados en IA, el uso de ontologías y diccionarios estructurados ha ganado relevancia para normalizar el dominio de la privacidad

[15], [16]. Vocabularios como el Data Privacy Vocabulary (DPV) [17] y ontologías especializadas como DataSecOnt [18] permiten modelar de forma precisa las categorías de datos y propósitos de tratamiento, facilitando una auditoría trazable y reproducible.

III. METODOLOGÍA

Esta sección detalla el marco metodológico diseñado para dar respuesta a las preguntas de investigación planteadas. El proceso se ha concebido como un flujo de trabajo sistemático y reproducible, estructurado de forma que sea fácilmente adaptable a otras categorías de aplicaciones móviles o a diferentes tipologías de datos personales. La arquitectura de este método permite contrastar la información declarativa orientada al usuario con las cláusulas legales detalladas en las políticas de privacidad, garantizando una auditoría técnica rigurosa y escalable. La Figura 1 ilustra las cuatro fases interconectadas que componen este estudio, las cuales se describen a continuación.

III-A. Fase 1: Obtención de los Datos

Esta primera fase se centra en la recolección y preparación del corpus de datos necesario para el estudio, asegurando una base sólida para el análisis posterior. El proceso comienza con la identificación de las fuentes de información y termina con la consolidación de una muestra representativa de aplicaciones de salud.

La obtención de activos se apoya principalmente en el repositorio *App-PIMD* [19], utilizando la Google Play Store como fuente primaria para la extracción de metadatos y documentos. Para cada aplicación, se consultan tres elementos clave: los metadatos descriptivos del *market*, la sección de Seguridad de los Datos (*Data Safety*), donde se encuentran los *Privacy Labels*, y la Política de Privacidad enlazada oficialmente en dicha sección.

Para garantizar la calidad e idoneidad de la muestra, se aplican de forma sistemática los siguientes criterios de inclusión y filtrado:

- **Categorización:** Debido a la naturaleza del estudio enfocado en *mHealth*, las aplicaciones deben pertenecer a la categoría `HEALTH_AND_FITNESS` de Google Play.
- **Disponibilidad de documentos:** Es imprescindible que la aplicación cuente con su sección de Seguridad de los Datos activa y un enlace funcional a su Política de Privacidad.
- **Posicionamiento:** El muestreo se realiza de forma aleatoria entre las aplicaciones destacadas en la página de portada de su categoría², asegurando que el estudio se centre en herramientas con una presencia relevante para el usuario final.

Tras aplicar estos filtros, se consolida el conjunto de datos final que se analizará compuesto por las aplicaciones. De cada una de ellas se almacena de forma estructurada el nombre del paquete, el nombre comercial y el corpus textual íntegro tanto de su Política de Privacidad como de su sección de Seguridad de los Datos. Este conjunto de datos proporciona el contexto necesario para ejecutar el análisis de discrepancias en las fases siguientes.

²https://play.google.com/store/apps/category/HEALTH_AND_FITNESS




Figura 1. Metodología empleada para resolver las preguntas de investigación.

III-B. Fase 2: Análisis de los Datos

Esta fase constituye el núcleo del estudio, donde se transforma el corpus textual en datos estructurados para evaluar la lealtad de las aplicaciones. El proceso se fundamenta en el uso de ontologías como base de conocimiento para una extracción semántica precisa y auditable. Así como para justificar la coherencia de las fuentes a la hora de hacer las declaraciones.

Para identificar la presencia de declaraciones sobre salud, se segmentan dos ontologías de referencia que modelan datos personales buscando el término más general que contiene “health”:

- **Análisis de Políticas de Privacidad (DPV-PD):** Se filtra la extensión de datos personales del *Data Privacy Vocabulary* por el término *Medical Health* y todas sus subclases (ej. *Genetic*, *HealthHistory*) [17]. Al estar basada en las categorías del RGPD, esta ontología garantiza que el análisis se alinea con los estándares legales europeos.
- **Análisis de Privacy Labels (DataSecOnt):** Se emplea la ontología *DataSecOnt* que modela los tipos de datos de la sección de Seguridad de los Datos de Google Play, filtrando por la categoría *Health and fitness* y sus conceptos derivados [18].

De este modo, se obtienen dos fragmentos ontológicos especializados que sirven como diccionarios estructurados para la extracción de información en cada tipo de documento (ver figuras 2 y 3).




Figura 2. Datos de salud según *DataSecOnt*.

La extracción se realiza mediante un proceso de inferencia por subsunción: si en el documento asociado (ya sea la política o la Seguridad de los Datos) aparece cualquier término específico perteneciente a las clases mencionadas, se marca automáticamente la presencia del concepto general respectivo, “Medical Health” o “Health and fitness” respectivamente. Por ejemplo, la detección del término *genetic* en una política de privacidad clasifica el texto como una declaración positiva de *Medical Health*. Por el contrario, la ausencia total de términos vinculados se registra como una declaración negativa de recopilación. Finalmente, para permitir la comparación entre ambas fuentes, se establece un emparejamiento (*approximate match*) entre los conceptos de nivel superior de ambas ontologías.

A diferencia de las aproximaciones basadas en modelos de lenguaje extenso (LLMs), este método basado en ontologías ofrece dos ventajas críticas para la auditoría de privacidad. En primer lugar, la **trazabilidad**: el marcado de una aplicación no depende del juicio opaco de una IA entrenada, sino de evidencias textuales exactas modeladas sobre documentos

legales y técnicos oficiales, permitiendo señalar qué término específico activó la detección. En segundo lugar, la **sostenibilidad**: el coste computacional y energético de este análisis es despreciable frente al entrenamiento y ejecución de grandes modelos, lo que facilita una auditoría masiva y reproducible del ecosistema *mHealth*.

III-C. Fase 3: Resultados e Interpretación

Esta fase se centra en la evaluación cuantitativa de las discrepancias detectadas, utilizando como herramienta principal de análisis las matrices de confusión generadas tras el cruce de ambas fuentes de información.

Para el cálculo de las métricas, se establecen las Políticas de Privacidad analizadas mediante *DPV* como la “verdad” o *ground truth* del estudio. Esta decisión metodológica se fundamenta en que la Política de Privacidad es el documento legalmente vinculante donde, según el marco normativo del RGPD, deben detallarse de forma exhaustiva todas las actividades de tratamiento de datos [1]. Mientras que las *Privacy Labels* son resúmenes orientados a la interfaz de usuario [2], la política constituye el contrato legal real entre el desarrollador y el usuario, lo que la convierte en la referencia de veracidad para auditar cualquier otra declaración simplificada. No obstante, esta decisión metodológica implica que los resultados deben interpretarse como una medida de consistencia declarativa entre dos fuentes proporcionadas por el desarrollador, y no como una verificación directa del comportamiento técnico real de la aplicación.

Sobre las matrices de confusión resultantes, se calculan tres ratios específicos diseñados para responder a los objetivos de este trabajo:

- **Ratio de Lealtad (RL):** Modela la proporción de aplicaciones cuyas declaraciones son consistentes en ambas fuentes (coincidencia de positivos y negativos). Esta métrica permite dar respuesta directa a la **PI2** sobre el porcentaje global de lealtad en el sector *mHealth*.
- **Ratio de Transparencia (RT):** Representa el porcentaje de aplicaciones que, declarando la recopilación de datos de salud en su Política de Privacidad (verdad), también lo reflejan correctamente en su sección de Seguridad de los Datos. Se utiliza para resolver la **PI3** sobre la fidelidad de las etiquetas de la tienda.
- **Ratio de Falsos Positivos (RFP):** Mide los casos en los que, no existiendo evidencia de recopilación en la Política de Privacidad, el desarrollador marca la categoría de salud en la etiqueta de la tienda. Esta métrica es fundamental para abordar la **PI4** sobre la sobredeclaración de prácticas de privacidad.

El análisis conjunto de estas métricas permite no solo cuantificar el volumen de aplicaciones que declaran datos de salud frente a las menciones en sus políticas (**PI1**), sino también identificar los sesgos de información que afectan al consentimiento informado del usuario.

III-D. Fase 4: Validación

La última etapa de la metodología consiste en un proceso de auditoría manual diseñado para verificar la fiabilidad de las detecciones automáticas y asegurar la integridad de las conclusiones extraídas.




Figura 3. Datos de salud según *Data Privacy Vocabulary - Personal Data Categories*.

Se extrae de forma aleatoria un subconjunto del conjunto de datos original, compuesto por unas pocas aplicaciones. Para cada una de estas aplicaciones, se realiza una revisión humana exhaustiva de sus Políticas de Privacidad y sus secciones de Seguridad de los Datos. El objetivo de esta tarea es contrastar la “adjudicación” automática de cada aplicación a las clases de la matriz de confusión (Verdaderos Positivos, Falsos Negativos, etc.) con la realidad textual de los documentos.

Esta validación permite confirmar que el proceso de inferencia por subsunción y el mapeo de términos entre *DPV* y *DataSecOnt* se ejecutan correctamente. Al verificar manualmente que los términos detectados corresponden efectivamente al contexto de recolección de datos de salud, se garantiza la precisión de los ratios calculados y se dota de una capa de confianza adicional a los resultados globales del estudio.

IV. RESULTADOS E INTERPRETACIÓN

En esta sección se presentan los hallazgos derivados del análisis de 171 aplicaciones móviles de salud recolectadas el 25 de enero de 2026. Los resultados permiten cuantificar la brecha de lealtad existente entre las declaraciones simplificadas de las tiendas de aplicaciones y las obligaciones legales detalladas en las políticas de privacidad. En la Tabla I, se muestra un extracto del conjunto de datos resultado de la aplicación de las Fases 1 y 2 de la metodología desarrollada.

A partir de este conjunto, se observa inicialmente cómo aplicaciones como *to.being.now* o *com.icare.iweight* omiten

la declaración de salud en su etiqueta de seguridad a pesar de mencionarla explícitamente en su política de privacidad. Estas inconsistencias individuales, procesadas de forma masiva para las 171 aplicaciones, permiten construir la matriz de confusión necesaria para dar respuesta a las preguntas de investigación planteadas.




Figura 4. Matriz de confusión resultado.

Los resultados de la comparativa entre las dos fuentes de información se sintetizan en la matriz de confusión presentada

Tabla I
EXTRACTO DEL CONJUNTO DE DATOS ANALIZADO (VERSIÓN SIMPLIFICADA).

Id de Aplicación	Nombre de la Aplicación	Declara Salud en la Sec. de Seguridad de los Datos	Declara Salud en la Política de Privacidad
to.being.now	being by lissun: self-therapy	No.	Sí.
com.kungfutrainertai.chichuan	Tai Chi Trainer	No.	No.
com.icare.iweight	AFit Health	No.	Sí.
com.iofit	SALTED Golf	Sí.	No.
cc.join.cycling	JOIN Training plan ciclista	Sí.	Sí.
⋮	⋮	⋮	⋮

en la Figura 4. En esta representación, las filas corresponden a la realidad técnica extraída de las Políticas de Privacidad (*ground truth*), mientras que las columnas reflejan las declaraciones en la sección de Seguridad de los Datos. Cada celda de la matriz se define de la siguiente manera:

- **Verdaderos Negativos (TN = 49):** Aplicaciones que no declaran datos de salud en ninguna de las dos fuentes.
- **Falsos Positivos (FP = 35):** Aplicaciones que declaran salud en la tienda, pero cuya política de privacidad no respalda dicha afirmación (sobredeclaración).
- **Falsos Negativos (FN = 32):** Aplicaciones que omiten la declaración en la tienda a pesar de que su política confirma la recopilación de datos de salud (omisión).
- **Verdaderos Positivos (TP = 55):** Aplicaciones que declaran consistentemente la recopilación de datos de salud en ambas fuentes (leal).

A partir de estos valores, se procede al cálculo de los ratios que permiten dar respuesta a las preguntas de investigación planteadas.

Volumen de Declaraciones (PI1) Al contrastar las fuentes de forma independiente, se observa que 87 aplicaciones mencionan datos de salud en sus políticas ($FN + TP = 32 + 55 = 87$, 50,9 %), mientras que el volumen detectado en las *Privacy Labels* asciende a 90 aplicaciones ($FP + TP = 35 + 55 = 90$, 52,6 %). Esta ligera diferencia inicial oculta, sin embargo, las discrepancias internas analizadas en los siguientes ratios.

Lealtad Global (PI2) Para evaluar el porcentaje de lealtad en el sector *mHealth*, se calcula la proporción de aplicaciones con declaraciones consistentes (la suma de aciertos TN y TP).

$$RL = \frac{TN + TP}{total} = \frac{49 + 55}{171} = 60,8\%$$

Ratio de Transparencia (PI3) Esta métrica evalúa cuántas de las aplicaciones que realmente tratan datos de salud (según su política de privacidad) lo comunican fielmente en la sección de Seguridad de los Datos.

$$RT = \frac{TP}{FN + TP} = \frac{55}{32 + 55} = 63,2\%$$

Ratio de Falsos Positivos (PI4) Finalmente, se analiza la sobredeclaración de prácticas de privacidad en las etiquetas respecto a lo estipulado en las políticas legales.

$$RFP = \frac{FP}{FP + TP} = \frac{35}{35 + 55} = 38,9\%$$

El análisis de estos ratios revela una realidad preocupante sobre la fiabilidad de las *privacy labels*. El hecho de que solo

un 60,8 % de las aplicaciones mantengan una coherencia total entre sus fuentes de información (PI2) sugiere que casi 4 de cada 10 aplicaciones ofrecen información contradictoria al usuario.

Especialmente relevante es el volumen de Falsos Negativos (FN=32) (PI2). Estos casos representan el escenario de mayor riesgo para la privacidad, ya que la aplicación recopila datos de salud según su política de privacidad pero omite declararlo en la sección de Seguridad de los Datos. Esta omisión impide que el usuario tome una decisión informada en el momento de la descarga, vulnerando el espíritu de las normativas de protección de datos como el RGPD.

Por otro lado, la tasa de Falsos Positivos del 38,9 % (PI4) sugiere un fenómeno de sobredeclaración o “etiquetado preventivo”. Este hallazgo es significativo porque indica que la falta de lealtad no siempre responde a una ocultación malintencionada de la recolección, sino posiblemente a una falta de sincronización técnica entre los equipos de desarrollo que completan la sección de la tienda y los equipos legales que redactan las políticas. Asimismo, parte de esta inconsistencia podría atribuirse a la propia rigidez de las *privacy labels*, cuyas categorías predefinidas pueden forzar a los desarrolladores a realizar declaraciones imprecisas por falta de opciones que se ajusten mejor a la realidad detallada en la política. No obstante, en cualquiera de los casos, esta práctica satura al usuario con información no fidedigna, contribuyendo a la fatiga de consentimiento y mermando la confianza en el ecosistema *mHealth*.

Finalmente, el hecho de que el volumen de declaraciones detectadas en las etiquetas (52,6 %) sea ligeramente superior al de las políticas (50,9 %) (PI1) demuestra que un análisis superficial de volumen no es suficiente para evaluar la transparencia. Solo mediante el análisis de discrepancias basado en ontologías se logra identificar que, aunque los totales son similares, las aplicaciones que declaran salud en una fuente a menudo no son las mismas que lo hacen en la otra, justificando la necesidad de auditorías automatizadas y trazables como la propuesta en este trabajo.

V. VALIDACIÓN

Para verificar la fiabilidad del método de inferencia basado en ontologías descrito en la Fase 2 de la Sección III, se ha llevado a cabo una auditoría manual sobre un subconjunto aleatorio de 10 aplicaciones (20 documentos en total). El objetivo de esta fase es determinar si el motor de búsqueda semántica identifica correctamente la presencia de datos de salud en comparación con un revisor humano que analiza el contexto completo de los documentos. Los resultados detallados de este proceso se presentan en la Tabla II.

Tabla II
RESULTADOS DE LA VALIDACIÓN MANUAL (SELECCIÓN ALEATORIA DE 10 APLICACIONES).

App ID / Documento	Fuente	Original	Manual	Evidencia / Observaciones
com.zeopoxa.pushups	DS	0	0	Sin declaración de categorías de salud.
	PP	0	0	Documento no disponible o inaccesible.
com.nutrition.tech.Fitia	DS	1	1	Declarado "Health and fitness" ("Fitness info").
	PP	0	0	Documento no disponible o inaccesible.
sixpack.sixpackabs...	DS	1	1	Detectado "Fitness info" (marcado como opcional).
	PP	1	1	Sección específica "Health data" en el texto.
com.sevenbold.cadence	DS	1	1	Declarado "Health and fitness" ("Fitness info").
	PP	1	1	Menciona integración con "Apple Health" y "Strava".
com.xiaomi.hm.health	DS	1	1	Declarado "Health info" y "Fitness info".
	PP	1	1	Menciona explícitamente a Zepp Health y datos de "heart rate".
io.noexcuse.fitseveneleven	DS	1	1	Declarado "Health and fitness" ("Fitness info").
	PP	0	0	No se detectan cláusulas de tratamiento de datos de salud.
com.nutria.app...	DS	0	0	Sin declaración de salud en la tienda.
	PP	0	1	Discrepancia: Menciona "información dietética" del usuario.
com.trainerize.goldsgym...	DS	1	1	Presencia de "Health info" y "Fitness info".
	PP	1	1	Referencia a la ley HIPAA y "Health info".
ch.unidesign.ladycycle	DS	0	0	No declara salud en la sección de seguridad.
	PP	1	1	Trata datos de "reproductive health" y "body temperature".
com.lw.linwear.smart.pro	DS	1	1	Declarado "Health info" y "Fitness info".
	PP	0	0	No se mencionan datos de salud.

La validación del método arroja una tasa de acierto global del 95 % (19/20 documentos analizados), lo que avala la solidez de la metodología y confirma que las discrepancias de lealtad reportadas en la Sección IV no son fruto de errores de detección, sino de inconsistencias reales en las declaraciones de los desarrolladores. En relación con la sección de Seguridad de los Datos (DS), se obtuvo una precisión del 100 % (10/10), un resultado esperado dado que esta fuente emplea un catálogo de categorías preestablecidas que nuestro método mapea de forma unívoca mediante la ontología *DataSecOnt*.

Por su parte, en el análisis de las Políticas de Privacidad (PP) la tasa de acierto fue del 90 % (9/10). Es importante destacar que en el 20 % de la muestra (2 de las 10 aplicaciones), el corpus textual era inexistente debido a archivos vacíos. En estos casos, el sistema asignó correctamente un valor de 0, validando su capacidad para evitar falsos positivos ante información no procesable, si bien la ausencia de estos documentos sugiere que los enlaces proporcionados por los desarrolladores podrían estar rotos o desactualizados. Finalmente, se identificó una única discrepancia en la aplicación *com.nutria.app...*, donde la revisión manual detectó menciones a "información dietética" no capturadas por el sistema. Esta omisión evidencia que, aunque el método es preciso, su rendimiento es sensible a la exhaustividad del diccionario ontológico frente a términos muy específicos, lo que abre una línea de mejora para ampliar el espectro semántico de las ontologías empleadas.

VI. CONCLUSIONES Y TRABAJO FUTURO

Este trabajo ha evaluado la lealtad de las aplicaciones de salud mediante un análisis de discrepancias basado en ontologías, revelando una brecha significativa en la transparencia del ecosistema *mHealth*. Los resultados indican que solo el 60,8 % de las aplicaciones de salud mantienen una consistencia total entre sus *Privacy Labels* y sus políticas de privacidad. Especialmente preocupante es el hallazgo de que un 36,8 % de las aplicaciones que realmente tratan datos de salud omiten esta declaración en la interfaz de la tienda, lo que compromete el consentimiento informado y vulnera los principios de transparencia y lealtad del RGPD.

Por otro lado, la tasa de sobredeclaración detectada (RFP=38,9 %) sugiere que los desarrolladores aplican "eti-quetado preventivo", lo que puede contribuir a la fatiga de consentimiento del usuario. El uso de un marco ontológico ha demostrado ser una alternativa técnica robusta, sostenible y, sobre todo, trazable frente a modelos de caja negra, permitiendo identificar inconsistencias.

Si bien la validación manual confirmó una precisión del 95 %, futuros trabajos ampliarán este corpus para fortalecer la representatividad estadística de los resultados de auditoría. Además, se plantean las siguientes líneas de investigación para fortalecer el estudio:

- *Ampliación del alcance del tratamiento:* Evolucionar el uso de ontologías para auditar no solo la presencia de categorías de datos, sino también la legitimidad de sus propósitos, los periodos de retención y la distinción entre recopilación local y compartición con terceros.
- *Análisis de factores de mercado:* Estudiar si el grado de lealtad detectado está correlacionado con la popularidad de la aplicación, su volumen de descargas o las valoraciones de los usuarios, permitiendo identificar si las aplicaciones más masivas cumplen mejor con sus obligaciones de transparencia.
- *Ampliación al comportamiento real de la aplicación:* Integrar en el estudio análisis técnicos, como análisis estático de código y funcionalidad, para contrastar si las declaraciones detectadas se traducen en comportamientos reales de la aplicación o no.

DISPONIBILIDAD DE DATOS

El código fuente desarrollado para el análisis de discrepancias basado en ontologías, así como los fragmentos de las ontologías utilizados, se encuentran disponibles de forma abierta en el siguiente repositorio: <https://doi.org/10.5281/zenodo.18826959>. Con el fin de garantizar un uso responsable de los datos recopilados y respetar la integridad de las fuentes originales, el conjunto de datos completo se facilitará bajo petición razonable al autor de correspondencia.

AGRADECIMIENTOS

Este trabajo se incluye en las actividades del Proyecto Estratégico de Ciberseguridad App-PI (App Privacy Impact): Un ecosistema para la evaluación del impacto de apps para dispositivos móviles sobre la privacidad y seguridad de sus usuarios (C120.23_UVa), el cual se realiza al amparo de un convenio de colaboración entre la Universidad de Valladolid y la S.M.E. Instituto Nacional de Ciberseguridad de España M.P., S.A. para la promoción de proyectos estratégicos de Ciberseguridad en España, en el marco de los Fondos del Plan de Recuperación, Transformación y Resiliencia, financiados por la Unión Europea (Next Generation).

Este trabajo ha sido financiado parcialmente por el Ministerio de Ciencia, Innovación y Universidades de España, en el marco del programa de ayudas para la Formación de Profesorado Universitario (FPU24/04222).

REFERENCIAS

- [1] Parlamento Europeo y el Consejo. (2016) Reglamento (UE) 2016/679 del Parlamento Europeo y del Consejo, de 27 de abril de 2016, relativo a la protección de las personas físicas en lo que respecta al tratamiento de datos personales y a la libre circulación de estos datos y por el que se deroga la Directiva 95/46/CE (Reglamento General de Protección de Datos). (Último acceso: 24/02/2026). [Online]. Available: <http://data.europa.eu/eli/reg/2016/679/oj>
- [2] P. Caven, Z. Zhang, J. Abbott, X. Ma, and L. Camp, "Comparing the use and usefulness of four iot security labels," in *Proceedings of the 2024 CHI Conference on Human Factors in Computing Systems*, ser. CHI '24. New York, NY, USA: Association for Computing Machinery, 2024. [Online]. Available: <https://doi.org/10.1145/3613904.3642951>
- [3] J. Krämer, "The death of privacy policies: How app stores shape gdpr compliance of apps," *Internet Policy ev.*, vol. 13, 2024.
- [4] L. F. Cranor, "Mobile-app privacy nutrition labels missing key ingredients for success," *Communications of the ACM*, vol. 65, pp. 26 – 28, 2022.
- [5] A. Pérez-Fuente, P.-A. Criado-Lozano, and M. M. Martínez-González, "Fake transparency: When mobile apps say one thing but do another," in *Proceedings of Fourth European Workshop on Algorithmic Fairness*, ser. Proceedings of Machine Learning Research, H. Weerts, M. Pechenizkiy, D. Allhutter, A. M. Corrêa, T. Grote, and C. Liem, Eds., vol. 294. PMLR, 30 Jun–02 Jul 2025, pp. 369–375. [Online]. Available: <https://proceedings.mlr.press/v294/perez-fuente25a.html>
- [6] D. R. Torrado, I. Yang, J. M. D. Álamo, and N. Sadeh, "Large language models: a new approach for privacy policy analysis at scale," *Computing*, vol. 106, pp. 3879 – 3903, 2024.
- [7] V. Bracamonte, S. Hidano, W. B. Tesfay, and S. Kiyomoto, "User study of the effectiveness of a privacy policy summarization tool," in *Information Systems Security and Privacy*, P. Mori, S. Furnell, and O. Camp, Eds. Cham: Springer International Publishing, 2020, pp. 186–206.
- [8] R. Khandelwal, A. Nayak, P. Chung, and K. Fawaz, "Unpacking privacy labels: A measurement and developer perspective on google's data safety section," in *33rd USENIX Security Symposium, USENIX Security 2024, Philadelphia, PA, USA, August 14-16, 2024*, D. Balzarotti and W. Xu, Eds. USENIX Association, 2024. [Online]. Available: <https://www.usenix.org/conference/usenixsecurity24/presentation/khandelwal>
- [9] T. Cory, W. Rieder, and T. Huynh, "A qualitative analysis framework for mhealth privacy practices," in *IEEE European Symposium on Security and Privacy Workshops, EuroS&PW 2024, Vienna, Austria, July 8-12, 2024*. IEEE, 2024, pp. 24–31. [Online]. Available: <https://doi.org/10.1109/EuroSPW61312.2024.00010>
- [10] G. Tangari, M. Ikram, K. Ijaz, M. A. Kâafar, and S. Berkovsky, "Mobile health and privacy: cross sectional study," *The BMJ*, vol. 373, 2021.
- [11] A. Jain, D. Rodríguez Torrado, J. D. Álamo, and N. Sadeh, "ATLAS: Automatically detecting discrepancies between privacy policies and privacy labels," in *2023 IEEE European Symposium on Security and Privacy Workshops (EuroS&PW)*, 2023, pp. 94–107.
- [12] D. Rodríguez Torrado, A. Jain, J. D. Álamo, and N. Sadeh, "Comparing privacy label disclosures of apps published in both the app store and google play stores," in *2023 IEEE European Symposium on Security and Privacy Workshops (EuroS&PW)*, 2023, pp. 150–157.
- [13] G. Feretzakis, E. Vagena, K. Kalodanis, P. Peristera, D. Kalles, and A. Anastasiou, "Gdpr and large language models: Technical and legal obstacles," *Future Internet*, vol. 17, p. 151, 2025.
- [14] B. Das, M. H. Amini, and Y. Wu, "Security and privacy challenges of large language models: A survey," *ACM Computing Surveys*, vol. 57, pp. 1 – 39, 2024.
- [15] D. Golpayegani, I. Hupont, C. Panigutti, H. J. Pandit, S. Schade, D. O'Sullivan, and D. Lewis, "Ai cards: towards an applied framework for machine-readable ai and risk documentation inspired by the eu ai act," in *Annual Privacy Forum*. Springer, 2024, pp. 48–72.
- [16] C. Esposito, R. Horne, L. Robaldo, B. Buelens, and E. Goesaert, "Assessing the solid protocol in relation to security and privacy obligations," *Information*, vol. 14, no. 7, 2023. [Online]. Available: <https://www.mdpi.com/2078-2489/14/7/411>
- [17] H. J. Pandit, B. Esteves, G. P. Krog, P. Ryan, D. Golpayegani, and J. Flake, "Data privacy vocabulary (dpv) – version 2.0," in *The Semantic Web – ISWC 2024*, G. Demartini, K. Hose, M. Acosta, M. Palmonari, G. Cheng, H. Skaf-Molli, N. Ferranti, D. Hernández, and A. Hogan, Eds. Cham: Springer Nature Switzerland, 2025, pp. 171–193.
- [18] A. Gavino-Dias González, "Datasecont: ontología para la seguridad de los datos de google play," Trabajo de Fin de Grado, Universidad de Valladolid, 2025. [Online]. Available: <https://uvadoc.uva.es/handle/10324/79367>
- [19] A. Pérez-Fuente, M. M. Martínez-González, A. Aparicio, and P. A. Criado-Lozano, "Metadata-based privacy assessment for mobile mhealth," *Sensors*, vol. 26, no. 3, 2026. [Online]. Available: <https://www.mdpi.com/1424-8220/26/3/870>

Evaluation of DNS Traffic Obfuscation Strategies for Defending Against Mobile User Profiling

Andrea Jimenez-Berenguel, Marta Moure-Garrido, Celeste Campo, Carlos García-Rubio

Universidad Carlos III de Madrid

Departamento de Ingeniería Telemática

andrejim@pa.uc3m.es, mamoureg@it.uc3m.es, celeste@it.uc3m.es, cgr@it.uc3m.es

Abstract—Mobile applications generate DNS queries that reveal user behavior patterns, even when communications are encrypted. In previous work, we proposed DNS Query Forgery (DQF), a client-side technique that injects fake DNS queries to obfuscate user profiles, but without defining a concrete generation strategy. In this paper, we adapt two zero-delay obfuscation strategies from Website Fingerprinting defenses, FRONT and GLUE, to mobile DNS traffic. Both inject fake queries without delaying real ones. We evaluate their effectiveness against a TF-IDF machine learning classifier and a characteristic domain (CD) method. At 40% overhead, the CD classifier's F1 drops from 0.815 to 0.404–0.486, while TF-IDF drops from 0.623 to 0.407–0.451. GLUE is most disruptive against CD ($F1=0.404$), while FRONT is most effective against TF-IDF ($F1=0.407$). These contrasting vulnerabilities highlight the importance of evaluating defenses against diverse attack models.

Index Terms—DNS privacy, user profiling, traffic obfuscation, mobile applications, machine learning

Type of contribution: *Original research (8-page limit)*

I. INTRODUCTION

The Domain Name System (DNS) is a core component of the Internet infrastructure. Every time a user interacts with a mobile application, their device issues DNS queries to resolve the domain names required for communication. Traditionally, these queries were sent in plaintext over port 53, DNS over port 53 (Do53), allowing any network observer to inspect the queried domains. To address this exposure, encryption protocols such as DNS over TLS (DoT) [1], DNS over HTTPS (DoH) [2], and DNS over QUIC (DoQ) [3] have been developed, and their adoption has grown in recent years. Today, most DNS traffic from mobile devices is transmitted using one of these encrypted protocols.

However, DNS encryption only protects queries against on-path network observers (*eavesdroppers*). The DNS server that resolves the queries still has full access to the requested domain names and, consequently, to the user's browsing and application usage history. A malicious or compromised DNS server can analyze the query stream generated by a device to classify traffic by application or to profile the user's habits.

In previous work [4], [5], we showed that mobile applications can be identified from their DNS queries with 98% accuracy. Through application identification, an attacker can infer a person's behavior and interests. This represents a privacy vulnerability even when the traffic is encrypted, as long as the attacker has access to the queried domain names.

Since encryption does not protect against the DNS server itself, client-side Privacy-Enhancing Technologies (PET) that do not rely on trusting third parties are needed. In prior

work [6], we proposed DNS Query Forgery (DQF), a client-side data perturbation technique that injects fake DNS queries into the user's traffic stream to distort their real profile. We modeled the user profile as a probability distribution over interest categories and quantified the privacy gain achieved by injecting different percentages of fake queries. Results showed that less than 20% of additional traffic can yield a 50% privacy improvement. However, DQF does not define a concrete strategy for generating and inserting fake queries.

Obfuscating network traffic to protect user privacy has been extensively studied in the context of Website Fingerprinting (WF), particularly over Tor networks. Xiao et al. [7] covers the main attacks and defense mechanisms against WF. Defenses employ techniques such as traffic pattern regularization, silence padding with dummy packets, and injection of traffic mimicking real webpage loads. Among the most notable defenses are WTF-PAD [8], RegulaTor [9], FRONT and GLUE [10]. These strategies introduce dummy packets following different strategies to hinder traffic classification. In particular, FRONT and GLUE are zero-delay defenses: they inject dummy packets without delaying any real packets, which makes them well-suited for practical deployment.

Building on these WF defense strategies, in this paper we select FRONT and GLUE [10] and adapt them to the context of DNS traffic obfuscation from mobile applications, implementing both as DQF mechanisms. We focus on these two strategies because they are zero-delay defenses: fake DNS queries are injected alongside real ones without postponing the real queries, preserving user experience. To evaluate their effectiveness, we use a TF-IDF-based Machine Learning (ML) classifier and the characteristic domain-based application identification method we proposed in [4]. In this way, we measure how each strategy and classifier combination reduces application identification and user profiling accuracy from the attacker's perspective.

In a recent work, Morozovič et al. [11] also confirm that behavioral DNS patterns alone suffice to re-identify users across sessions. While protocols such as DoH, DoT protect query content from on-path observers, they do not prevent the resolver from building user profiles.

The goals of this work are:

- To adapt and implement FRONT and GLUE, two zero-delay traffic obfuscation strategies from the WF defense literature, for DNS-based user profiling.
- To evaluate the effectiveness of each strategy using different traffic classification techniques (application identification and user profiling).

- To analyze the trade-off between privacy gain and the traffic overhead introduced by fake queries.

The remainder of this paper is organized as follows. Section II reviews the related work. Section III describes the synthetic user creation process. Section IV details the adaptation and implementation of the obfuscation strategies. Section V presents the experimental evaluation. Section VI draws conclusions and outlines future work.

II. RELATED WORK

This section reviews the literature most relevant to this work. First, we examine DNS traffic classification for user profiling and application identification. Then, we survey traffic obfuscation mechanisms proposed in the WF context, which we adapt to the DNS setting in Section IV.

A. DNS traffic classification

DNS traffic has been used to build behavioral fingerprints for a range of purposes, from detecting anomalous and malicious activity to identifying users and applications. Singh et al. [12] propose BotDAD, which generates hourly DNS fingerprints per host using features such as query rates, uniqueness ratios, and flux ratios, and applies a Random Forest to detect bot-infected machines with 99% accuracy. In the same vein, Fan et al. [13] exploit the periodic regularity of DNS queries from IoT botnets: by applying Shannon entropy and ANOVA to time interval sequences, they distinguish the repetitive patterns of malware from those of benign devices, achieving 92.05% accuracy.

Beyond behavioral timing, the lexical structure of queried domain names has also been exploited to detect malicious traffic. Vranken and Alizadeh [14] apply TF-IDF to character n-grams of domain name strings to detect algorithmically generated domains (DGAs), obtaining an AUC of 0.995 with a deep MLP model. Wu et al. [15] incorporate TF-IDF in the second stage of FTPB, a three-stage pipeline for DNS tunnel detection that combines character-level features with PCA-reduced TF-IDF vectors, reaching accuracy and precision above 99% for both content-based and codebook-based tunnels. Perdisci et al. [16] apply a document-retrieval weighting scheme analogous to TF-IDF to domain query probabilities in IoTFinder, enabling passive identification of IoT devices at ISP scale from their DNS fingerprints alone.

At the user level, Chang et al. [17] propose DSCORR, a tracking mechanism that uses Word2Vec domain embeddings to capture contextual correlations between DNS sessions and re-identify users even under dynamic IP addresses, reaching an AUC of 0.87 in an open-world setting. Morozovič et al. [11] also target user re-identification, building fingerprints from domain category frequencies and daily behavioral statistics, and comparing several ML models; their CNN achieves 86.7% accuracy across 1,727 users.

In our previous work, we addressed a finer-grained problem: identifying the specific mobile applications running on a device from their DNS queries. In [5], we showed that Android apps generate distinctive DNS query patterns, and by extracting characteristic domains a identification accuracy of 88.75% was achieved across 80 applications without resorting to machine learning. In [4], we refined this using effective

second-level domains (e2LDs), TTL, and DNS cache behavior, reaching 98% accuracy with 70% of apps identifiable within the first five minutes of execution.

Unlike Chang et al. and Morozovič et al., which aim at *user re-identification* across sessions from network-level observations, our work targets *application-level profiling*: inferring the set of applications running on a user's device from DNS query patterns visible to the resolver. The defense we address, DQF [6], operates entirely on the client device without modifications to DNS infrastructure, unlike LDPRE-SOLVE [17], which requires resolver-level changes. In this work, we leverage the characteristic domain method from [4] and TF-IDF-based classification to measure user profiling accuracy before and after applying WF defense mechanisms.

B. Defense Mechanisms

Defense mechanisms against traffic fingerprinting have been extensively studied, particularly in the context of WF. WF is a type of traffic analysis attack that allows an attacker to recover the browsing history of a client. In the same way, a DNS server can analyze DNS queries to recover the application usage history of a client. Defense mechanisms against WF are therefore directly applicable to DNS-based profiling. We reviewed the mechanism defense which conceals patterns in web traffic by adding varying amounts of dummy packets and/or delays to flows. The literature classifies WF defenses into three main categories: regularized defenses, non-regularized defenses, and adversarial defenses.

Regularized defenses mold traffic traces into a predefined pattern so that traces from different pages become indistinguishable. Cai et al. [18] propose Tamaraw, which extends BuFLO [19] by enforcing a fixed packet rate and a variable session length, reducing attack success to 3.4% at 199% bandwidth overhead. Wang et al. [20] propose Walkie-Talkie, which forces half-duplex communication to make monitored and non-monitored traces indistinguishable, achieving 31% bandwidth overhead, though it was later undermined by CNN-based attacks [21].

Holland et al. [9] introduce RegulaTor, which regularizes the shape of traffic surges by applying an exponentially decaying sending rate and filling gaps with dummy packets from a limited budget. In the closed-world setting, RegulaTor reduces the accuracy of the Tik-Tok attack to 25.4% with 79.7% bandwidth overhead, outperforming FRONT-2500 (66% accuracy, 119% overhead).

Non-regularized defenses inject dummy packets to alter specific traffic features without delaying real transmissions. Juárez et al. [8] propose WTF-PAD (*Website Traffic Fingerprinting Protection with Adaptive Defense*), which uses a state machine to fill silence gaps with dummy packets whose timing is sampled from histograms built from real traffic. WTF-PAD imposes no latency overhead, but Sirinam et al. [21] show that a CNN-based attack (Deep Fingerprinting) achieves over 90% accuracy against it in the closed-world setting.

Gong et al. [10] propose FRONT (*Front Randomized Obfuscation of Network Traffic*), which concentrates dummy packets at the beginning of traces (where the most discriminative features reside), sampling their timing from a Rayleigh distribution and randomizing the number of dummies per trace. With 33% data overhead, FRONT outperforms WTF-PAD

under the same budget. The same work introduces GLUE, which fills idle periods between consecutive page loads with dummy traffic, merging them into a single continuous trace and forcing the attacker to solve a splitting problem. With 22–44% overhead, GLUE reduces the true positive rate and precision of state-of-the-art attacks to single-digit values.

Wang et al. [22] propose TBP (*Tree structure Burst-sequence Padding*), which injects dummy burst sequences to disrupt the tree structure of webpage traces, reducing attacker true positive rate by 60% with 55% data overhead and outperforming FRONT at a comparable protection level.

Adversarial defenses exploit the vulnerability of deep-learning classifiers to crafted perturbations. Rahman et al. [23] propose Mockingbird, which iteratively shifts traffic traces toward random targets, reducing CNN attack accuracy from 98% to 42–58% with 58% overhead. Hou et al. [24] propose WF-GAN, a GAN that learns to perturb traffic to resemble target websites, achieving a 90% defense success rate with at most 15% overhead. Gong et al. [25] propose Surakav, which trains a GAN to generate realistic sending patterns adjusted to buffered data, outperforming FRONT with 42% less overhead at a comparable protection rate.

In this work, we focus on FRONT and GLUE [10], two non-regularized, zero-delay defenses from the WF literature. Both have been widely studied: Wang et al. [22] compare TBP against FRONT, and Gong et al. [26] evaluate FRONT alongside RegulaTor and Tamaraw in a real-world Tor deployment. We select FRONT and GLUE because they add no latency to real traffic, which makes them directly applicable as client-side DQF mechanisms, as described in Section IV.

III. SYNTHETIC USER CREATION

We conduct our experiments on a synthetic user dataset that we created in [6]¹. Generating synthetic users was necessary due to the scarcity of public datasets containing per-user application traffic, driven by privacy restrictions.

A. Base Dataset Selection

We evaluated three mobile application traffic datasets: CrossMarket [27] (229 applications, 5-minute traces), Mankowski [28] (90 applications, 5-minute traces), and MAppGraph [29] (81 applications, with an average of 330 minutes per trace, collected in 2021). We selected MAppGraph for its greater breadth and traffic diversity, with long traces that enable the generation of users with varied profiles.

B. Creation Process

Starting from the per-application PCAPs in the MAppGraph dataset, we extracted the domain names and timestamps from DNS request packets generated by the mobile device. An *application trace* is defined as the ordered list of DNS domain names queried during the execution of a single application, together with their timestamps. A *user trace* is defined as the ordered list of DNS queries generated by a user over a period of time, containing traffic interleaved from multiple

applications. In both cases, timestamps are relative to the start of the trace: the first query is assigned timestamp 0.

The synthetic user creation follows the process we described in [6]: *i*) we grouped 80 of the 81 MAppGraph applications (one was omitted due to insufficient traffic data) into 10 categories following the Google Play classification, where installation probabilities follow a power-law distribution both across and within categories; *ii*) for each synthetic user, we sample a weight vector over the 10 categories from the power-law distribution, yielding a unique interest profile (some categories may receive zero weight); *iii*) for each category with non-zero weight, we randomly select an application weighted by the within-category distribution; and *iv*) each user trace comprises T minutes of observed traffic, where T is a design parameter, with the time allocated to each application proportional to its usage weight, extracting traffic segments from the MAppGraph dataset at random starting points to avoid identical patterns across users.

To ensure independence between classifier training and evaluation, we split the MAppGraph captures at the trace level. For applications with fewer than 4 captures, at least one complete trace is reserved for the user creation subset. For applications with 4 or more captures, 75% of the traces are allocated to training and the remainder to user creation. This guarantees that all synthetic user traces are composed exclusively of traffic segments unseen during classifier training. In this work, we generate a set of 100 synthetic users from the user creation subset (25% of the dataset). The limited amount of available traffic in this subset constrains the trace duration to $T = 50$ min per user.

IV. IMPLEMENTATION OF OBFUSCATION STRATEGIES

Starting from the WF defense strategies described in Section II-B, we adapted FRONT and GLUE to the context of DNS traffic generated by mobile applications. In the original setting, these strategies introduce dummy packets into the web traffic stream; in our case, dummy packets translate into fake DNS queries to domains selected according to each strategy. Table I summarizes the characteristics of both adapted strategies.

A. Domain Pool for Fake Queries

For FRONT, whenever a fake DNS query is needed, the domain is randomly selected from a pool containing all unique e2LDs queried in the MAppGraph dataset. This way, the domains in fake queries match those naturally queried by mobile applications, making them indistinguishable from real ones at the content level. GLUE uses a different mechanism based on real application traffic, as described below.

B. FRONT Adapted to DNS Traffic

1) *Original FRONT*: In the WF context, a *trace* is the sequence of network packets recorded during a single webpage load, from the first request to the last incoming packet. Gong et al. [10] observe that WF attacks rely heavily on the *trace front*: the first few seconds of each trace contain the most discriminative features, and most classifiers explicitly exploit this region. FRONT therefore concentrates dummy packets precisely at the beginning of each trace.

¹The original MAppGraph PCAP files are available upon request to the dataset authors at <https://soeai.github.io/mappgraph/>. The scripts used to generate the synthetic users and apply the obfuscation strategies are publicly available at https://github.com/AndreaJimBerenguel/user_profiling.

The design has two key parameters: the *sample budget* (n_c , the number of dummy packets to inject) and the *sample window* (w_c , the time window within which they are injected). For each trace, n_c is drawn from a discrete uniform distribution $\bar{U}(1, N_c)$ and w_c from a continuous uniform distribution $U(W_{\min}, W_{\max})$, where N_c , $W_{\min}$, and $W_{\max}$ are configurable parameters. The dummy packet timestamps are then sampled from a Rayleigh distribution. This distribution concentrates dummy packets at the start of the window and gradually decreases their density. No real packets are delayed.

2) *DNS Adaptation*: In our mobile DNS setting, application execution replaces webpage loads as the unit of analysis: a user trace is composed of sequential *application segments*, each corresponding to a period of use of one app.

Rather than randomizing the sample budget per segment, we expose it as a global input parameter p (target overhead percentage), so that the total number of fake queries is fixed at $\lfloor N_{\text{real}} \times p/100 \rfloor$, where N_{real} is the total number of real queries in the user trace. This gives direct, reproducible control over traffic overhead: changing p changes the overhead proportionally, enabling fair comparisons at different overhead levels. Fake queries are then distributed among application segments proportionally to each segment’s execution time, so that longer sessions receive more dummy queries.

For the sample window, we fix the *padding window* to the first 10% of each segment’s duration, rather than drawing it randomly. Dummy queries are injected exclusively within this window, with timestamps sampled from a Rayleigh distribution and shifted to the segment start time. This concentrates the dummies at the very beginning of each application segment, mirroring the original FRONT’s approach of targeting the most discriminative trace region.

For example, with $p = 25\%$ and a user with 1,000 real queries across five applications with execution times of 50, 20, 10, 10, and 10 minutes, 250 dummy queries are injected in the proportions 125, 50, 25, 25, 25 within the first 10% of each application’s runtime.

C. GLUE Adapted to DNS Traffic

1) *Original GLUE*: GLUE exploits the concept of *dwell time*: the period between the end of loading one webpage and the start of loading the next, during which the user is reading the page. In the WF setting, dwell time gaps are obvious silence periods that allow an attacker to trivially split a multi-page trace into individual singleton traces and classify each one. GLUE fills these gaps with dummy traffic mimicking a new webpage load, forcing the attacker to solve a much harder splitting problem: determining how many pages were visited and where each one starts and ends.

In the original design [10], dwell time is detected via the client’s state machine: once the browser finishes loading a webpage, the client transitions to a *dwelling* state. While dwelling, the client exchanges dummy packets with the co-operative Tor relay, with inter-arrival times sampled from the distribution observed during the real trace to mimic an ongoing page load. Dummy injection ends either when the user navigates to a new page or when the dwell time exceeds a configurable maximum duration $d_{\max}$.




Fig. 1. Histogram of inter-query arrival times across the MAppGraph dataset. Green: intra-burst region; orange: transition and inter-burst periods. Spikes at 30 s and 60 s mark boundaries between these regimes and idle traffic.

2) *DNS Adaptation*: Our DNS trace setting lacks the real-time client state machine present in the original WF deployment. Instead, we detect silence periods statically from the trace inter-arrival time distribution. Analysis of the complete MAppGraph dataset reveals two distinct regimes: inter-query times below approximately 5.4 s correspond to intra-burst and burst-transition activity, while times in the 5.4–30 s range correspond to inter-burst activity. The histogram in Fig. 1 shows a pronounced spike at 30 s, marking the boundary between active app use and genuine idle periods (the user is between applications or reading content). A second spike at 60 s corresponds to longer inactivity periods. We therefore set the default *silence threshold* to $S = 30$ s: any inter-query gap exceeding this value is treated as a dwell period, and dummy traffic is injected into it.

Instead of injecting dummy packets mimicking a random webpage load (as in the original), we extract a contiguous fragment of real DNS queries from a randomly chosen application trace in the training subset. Using real application traffic makes the injected queries indistinguishable from genuine app activity at the domain level, which is more effective against domain-based classifiers. The duration of the injected fragment is bounded by a second parameter, d_g (*glue_duration*, default $d_g = 10$ s); note that d_g does not need to match the detected silence duration and can be longer. The amount of overhead introduced by GLUE is jointly controlled by both parameters: a smaller silence threshold S causes more gaps to be detected and filled, while a larger d_g injects longer traffic fragments into each detected gap. Both parameters therefore contribute to increasing the proportion of fake queries in the trace.

D. Application to User Traces

To apply a defense mechanism to a user trace, both strategies follow a common pipeline: the user trace is loaded, segmented by application, the defense mechanism is applied to each segment, and the defended trace is saved.

Figs 2 and 3 compare the DNS query distribution of a synthetic user with and without obfuscation. The x-axis shows the trace timeline divided into 5-minute intervals; the y-axis shows the number of queries in each interval. For each interval, the green bar represents the original trace, and the orange bar represents the obfuscated trace.

The figures illustrate the different injection patterns of each strategy. With FRONT, elevated intervals appear only at what




Fig. 2. Original vs. FRONT-obfuscated trace. Fake queries concentrate in the first 10% of each application segment.




Fig. 3. Original vs. GLUE-obfuscated trace. Fake queries fill silence periods throughout the trace.

appear to be the beginnings of application segments: fake queries are injected exclusively within the first 10% of each segment’s duration, producing localized spikes at the start of each app’s execution. Intervals where the two bars are equal height correspond to periods outside the injection window, where no fake queries were added. With GLUE, elevated intervals are distributed more homogeneously across the entire trace: GLUE injects fake traffic wherever it detects a silence period, which occurs throughout the trace.

V. EXPERIMENTAL EVALUATION

Having defined, adapted, and implemented FRONT and GLUE, we evaluate their effectiveness against two application profiling techniques: a ML classifier based on TF-IDF vectorization of DNS domain names, and a statistical classifier based on Characteristic Domains (CDs) [4].

We conduct our evaluation in the *closed-world setting*. In this setting, the attacker knows the complete list of applications a client may run, collects labeled traffic traces, and trains its models to infer which applications are present in a captured trace. Classification accuracy serves as our primary measure of privacy leakage: a higher accuracy indicates more information extracted from the DNS traffic stream, and therefore a higher privacy risk for the user.

The experimental scenario assumes a client and a DNS server communicating over Do53. The client uses one mobile application at a time: it launches an app, generates DNS traffic, closes it, and then launches another. The user trace therefore consists of separate, sequential application segments. The attacker is a passive, on-path eavesdropper (or equivalently, a malicious DNS server) who has access to the complete DNS traffic stream but does not know the temporal boundaries between application segments and must infer the set of running applications from the undivided trace.

A. Classifiers

1) *TF-IDF Classifier*: The TF-IDF classifier treats each application trace as a text document. All queried DNS domains are extracted and a *level reduction* is applied: each domain is truncated to its last two levels (e.g., `p9-sg.tiktokcdn.com` $\rightarrow$ `tiktokcdn.com`), or to three levels if the original domain has more than three components (e.g., `x.y.metric.gstatic.com` $\rightarrow$ `metric.gstatic.com`). The reduced domains of each trace are concatenated into a single string, forming the document representation of that application execution.

Each document is vectorized using TF-IDF, which weights each domain by its frequency within the document (*term frequency*) multiplied by the inverse of the proportion of documents that contain it (*inverse document frequency*). This emphasizes domains that are frequent in a particular application’s trace but rare across the full corpus, capturing each application’s discriminative vocabulary. The classification model uses a One-vs-Rest (OVR) architecture: one independent binary classifier per application, based on a stochastic gradient descent (SGD) estimator with the modified Huber loss. This setup yields independent per-application probabilities that do not necessarily sum to one, which is essential since a single user trace may contain traffic from multiple applications simultaneously. Both the TF-IDF vectorizer and the classifiers are trained exclusively on the MAppGraph training subset described in Section III, which is further split into 70% for training and 30% for validation with stratified sampling.

For user profiling, the entire user trace is processed using a sliding window of 15 minutes: overlapping windows of the trace are extracted, classified independently, and the per-application detection scores are aggregated across all windows to produce a final per-application probability. An application is considered detected if its aggregated probability exceeds a detection threshold $\tau = 1/N_{\text{apps}}$.

2) *Characteristic Domain Classifier*: The CD classifier is based on a predefined matrix that associates each of the 80 applications with one or more *characteristic domains* (the e2LDs most frequently queried exclusively by that application), or with domain tuples when the joint presence of two domains is required for unambiguous identification. The matrix is constructed by applying the methodology of [4] to the MAppGraph training subset described in Section III.

For a given user trace, all DNS domains are reduced to two or three levels (with special rules for compound TLDs such as `com.vn` and `gov.vn`, reduced to four levels to preserve the meaningful sub-hierarchy) and sorted by descending query frequency. For each application a , a score is computed as

$$\text{score}(a) = \sum_{m \in \text{matches}(a)} \frac{1}{w_m}, \quad (1)$$

where w_m is the position of the matched domain in the frequency-sorted list (lower position $\Rightarrow$ higher frequency $\Rightarrow$ higher contribution). For domain tuples, both components must be present and their positions are summed. Scores are normalized into probabilities $P(a) = \text{score}(a) / \sum_{a'} \text{score}(a')$, and an application is detected if $P(a) > \tau = 1/N_{\text{apps}}$.

TABLE I
COMPARISON OF THE OBFUSCATION STRATEGIES ADAPTED TO DNS TRAFFIC.

Strategy	Goal	When it injects	Fake query type	% Control
FRONT	Obfuscate app start	Start of each app segment	Random domains from pool	Direct (%)
GLUE	Fill silence periods	Silence periods ($> S$)	Traffic from random app	Indirect (S, d_g)

In the context of DNS obfuscation evaluation, injecting fake queries can affect the CD classifier in two ways: fake queries may introduce CDs of applications that are not in use (increasing false positives) or may alter the domain frequency ranking, pushing real CDs to lower positions and reducing their score contribution.

B. Evaluation Metrics

For each classifier and obfuscation strategy combination, we measure Precision, Recall, F1 Score and traffic overhead per synthetic user and report the mean across all 100 users.

In our setting, these metrics measure the attacker's ability to build an accurate user profile. A high Precision means that most detected applications are truly used, so the attacker obtains a reliable (if possibly incomplete) profile. A high Recall means the attacker detects most of the applications actually present in the traffic. A low Precision is favorable for user privacy: the attacker's profile is contaminated with false detections, making it unreliable even when Recall remains high. A low Recall is also favorable: the attacker misses a large fraction of the applications actually in use, producing an incomplete profile.

Beyond aggregate P/R/F1, we track the mean number of detected applications ($\bar{N}_{\text{det}}$) and compare it to the mean number of truly used applications averaged across all 100 synthetic users ($\bar{N}_{\text{true}} = 6.31$). If $\bar{N}_{\text{det}} \gg \bar{N}_{\text{true}}$, the classifier over-detects, inflating the profile with many false applications; Precision suffers accordingly. For example, detecting 72 applications when only 7 are real (Precision=0.08) renders the profile useless. Conversely, if $\bar{N}_{\text{det}} \ll \bar{N}_{\text{true}}$, the classifier under-detects; Recall suffers. For instance, detecting only 3 of 4 real applications (Recall=0.50) leaves the profile incomplete. In both cases, the defense has succeeded in preventing accurate user profiling.

C. Results

Below we describe the results obtained for each classifier under the five evaluated conditions: the unobfuscated baseline, FRONT at 10% and 40% overhead, and GLUE at 10% and 40% overhead. The main results are summarized in Table II.

1) *Baseline (no obfuscation)*: Without obfuscation, the CD classifier achieves mean $P=0.860$, $R=0.793$, $F1=0.815$, detecting on average 5.93 applications per user (very close to the true mean of 6.31). As visible in Fig. 4, the unobfuscated baseline is clearly separated from all defended configurations, confirming that CD successfully profiles the majority of users in the absence of obfuscation. The TF-IDF classifier achieves mean $P=0.874$, $R=0.518$, $F1=0.623$, but detects only 4.12 applications per user. Fig. 5 shows more intermixed results across conditions, reflecting TF-IDF's tendency to under-detect even without obfuscation: the classifier misses a substantial fraction of the apps actually present in the traffic.




Fig. 4. CD classifier: per-user F1 score for the baseline and each obfuscation condition. The baseline is clearly separated from all defended configurations.




Fig. 5. TF-IDF classifier: per-user F1 score for the baseline and each obfuscation condition. Results are more intermixed across conditions.

2) *Effect of FRONT*: Against CD, FRONT consistently reduces Precision while Recall remains high: the attacker still detects most real apps but also a large number of false ones, severely contaminating the user profile and leading to over-detection. At 10% overhead, Precision drops from 0.860 to 0.453 and at 40%, Precision falls further to 0.369.

Against TF-IDF, FRONT triggers over-detection causing Precision to drop from 0.874 to 0.629 at 40% overhead while Recall remains comparably stable (0.518 to 0.549). Although the attacker still detects most of the real applications (Recall is preserved), the profile is flooded with a large number of false detections, making it unreliable for practical inference of user behavior. As shown in Fig. 5, FRONT at 40% overhead yields the lowest per-user F1 scores across the majority of users.

3) *Effect of GLUE*: Against CD, GLUE at 10% has a more moderate effect than FRONT ($P=0.583$, $F1=0.667$). At 40% overhead, however, GLUE surpasses FRONT as the most disruptive strategy: Precision falls to 0.281 and the mean detected app count rises to 17.29, making the attacker's profile unreliable. In Fig. 4, GLUE at 40% overhead yields the lowest per-user F1 scores across all CD classifier conditions.

Against TF-IDF, GLUE behaves differently from FRONT: rather than inflating the profile, it suppresses detection. At 10%, the impact is minimal ($P=0.829$, $F1=0.575$). At 40%, Recall drops to its lowest value across all TF-IDF conditions (0.379) while Precision remains moderate (0.636), producing an incomplete rather than contaminated profile.

D. Discussion

1) *Differences between classifiers*: CD is a statistical classifier: it matches domain names against a pre-built catalogue of characteristic domains without any learned filtering. TF-IDF is a machine learning classifier that learns weighted

TABLE II
MEAN PRECISION (P), RECALL (R), AND F1 PER CLASSIFIER AND OBFUSCATION CONDITION. BOLD: MOST DISRUPTIVE STRATEGY. OVER-DETECTION = PROFILE INFLATION (FALSE DETECTIONS); UNDER-DETECTION = PROFILE SUPPRESSION (MISSED DETECTIONS).

Condition	CD Classifier				TF-IDF Classifier			
	P	R	F1	Effect	P	R	F1	Effect
Baseline	0.860	0.793	0.815	—	0.874	0.518	0.623	—
FRONT 40%	0.369	0.764	0.486	over-detection	0.629	0.549	0.407	over-detection
GLUE 40%	0.281	0.750	0.404	over-detection	0.636	0.379	0.451	under-detection




Fig. 6. Mean F1 score per classifier and obfuscation condition.

domain representations during training. This fundamental difference explains their contrasting behavior under obfuscation.

Without defense, CD significantly outperforms TF-IDF ($F1 = 0.815$ vs. 0.623) and it detects nearly the right number of apps per user ($\bar{N}_{\text{det}} = 5.93$ vs. $\bar{N}_{\text{true}} = 6.31$). TF-IDF already under-detects at baseline (4.12 apps on average). Its high Precision at baseline reflects selectivity rather than accuracy: the apps it does detect are mostly correct, but it misses many.

2) *Which strategy is most disruptive?*: As visible in Fig. 6, GLUE at 40% overhead achieves the lowest F1 score against CD ($F1 = 0.404$), making it the most effective strategy against the statistical classifier. This is because GLUE injects real application traffic fragments during silence periods: these fragments contain the characteristic domains of real apps, which the CD classifier directly matches and interprets as false detections. The more “authentic” the injected traffic, the more convincingly it fools a domain-matching classifier.

For TF-IDF, FRONT at 40% overhead achieves the lowest F1 ($F1 = 0.407$). FRONT injects random domains from the full application pool at the beginning of each app segment, generating false domain-frequency signals that alter the TF-IDF weighted vectors and push them across the classification boundaries for other applications, creating over-detection for a significant fraction of users.

3) *Summary of main results*: Table II summarizes the key metrics for the most impactful overhead level (40%) alongside the baseline; Fig. 6 provides a visual overview of the F1 scores across all evaluated conditions.

At baseline, both classifiers achieve similar Precision, but TF-IDF already under-detects: it misses a fraction of the apps actually present in the traffic, which explains its lower F1 (0.623 vs. 0.815 for CD), as visible in Fig. 6.

Under obfuscation, CD is more affected: both FRONT and GLUE cause over-detection, inflating the attacker’s profile beyond the true app count, making it unreliable. However, the two strategies affect TF-IDF differently: FRONT causes over-

detection, while GLUE causes under-detection, as the injected traffic masks the real signal and prevents the classifier from detecting genuinely present applications.

The most disruptive strategy against CD is GLUE ($F1 = 0.404$ at 40%), and the most disruptive against TF-IDF is FRONT ($F1 = 0.407$ at 40%) as represented in Fig. 6.

4) *Comparison with theoretical DQF results*: Our experimental findings can be compared with the theoretical analysis of DNS Query Forgery (DQF) presented in [6]. In that work, privacy gain was quantified as the increase in entropy of the user profile distribution when injecting a given percentage of fake queries, showing that injecting 20% fake queries could yield up to a 50% privacy improvement under idealized conditions. In the present study, we implement concrete, realistic obfuscation strategies (FRONT and GLUE) and evaluate their impact using practical classifiers. While both approaches confirm that moderate overheads can significantly degrade profiling accuracy, our results reveal that the actual privacy gain depends strongly on the attacker’s classifier and the obfuscation mechanism. For example, at 40% overhead, the F1 score drops by more than 50% for the most vulnerable classifier, but the effect is less pronounced for more resilient models. This highlights the importance of evaluating DQF strategies not only in theory but also against concrete attacks and real-world classifiers.

5) *Scope and limitations*: This work has two delimiting design choices. First, DQF is a client-side defense: it operates exclusively on the user’s device without requiring modifications to DNS infrastructure or trust in external entities. Server-side approaches such as LDPRESOLVE [17], which applies local differential privacy at the resolver, and Oblivious DoH [30], which decouples client identity from query content through an intermediate proxy, can also reduce profiling accuracy, but both require trust in an external party. In our threat model the resolver itself is the adversary, so these solutions are outside scope; DQF and server-side defenses are complementary and could be combined in deployments where partial resolver trust is available. Second, we evaluate DQF against two attack models: one statistical (CD) and one ML-based (TF-IDF). We plan to extend the evaluation to a more diverse attacker set, covering additional attack scenarios to enable a broader comparison of defense effectiveness.

VI. CONCLUSIONS AND FUTURE WORK

In this paper, we adapted and implemented two zero-delay traffic obfuscation strategies from the WF defense literature (FRONT and GLUE) to the context of DNS-based user profiling from mobile applications. Both strategies inject fake DNS queries without delaying real ones. We integrated them as mechanisms within the DQF framework [6], providing

concrete and parametrizable strategies for generating and inserting fake DNS queries into a user's traffic trace. Our evaluation against a statistical (CD) and a machine-learning (TF-IDF) classifier shows that, at 40% overhead, both defenses halve the attacker's F1 score, with GLUE being most disruptive against CD (F1 from 0.815 to 0.404) and FRONT against TF-IDF (F1 from 0.623 to 0.407).

Several directions remain for future work. First, we plan to extend the attacker evaluation to deep-learning classifiers (CNN, LSTM), adaptive attackers that retrain on defended traffic, and splitting techniques that exploit temporal correlations to detect injected queries. Second, validation with real users and longer observation windows (beyond 50 minutes) would test the robustness of the defenses under realistic conditions. Third, we intend to measure the impact of fake query injection on DNS resolution latency and on device resource consumption (battery usage and energy efficiency) under different network conditions. Finally, we plan to evaluate additional WF defense strategies adapted to DNS and to explore combinations of client-side and server-side defenses to map the privacy-overhead trade-off more broadly.

ACKNOWLEDGMENTS

This work has been supported by the Grant DISCOVERY (PID2023-148716OB-C33) funded by MICIU/AEI/10.13039/501100011033 and FEDER, UE and by Comunidad de Madrid (Spain) under the project RAMONES-CM (TEC2024-COM504).

REFERENCES

- [1] Z. Hu, L. Zhu, J. Heidemann, A. Mankin, D. Wessels, and P. E. Hoffman, "Specification for DNS over Transport Layer Security (TLS)," RFC 7858, May 2016.
- [2] P. E. Hoffman and P. McManus, "DNS Queries over HTTPS (DoH)," RFC 8484, Oct. 2018.
- [3] C. Huitema, S. Dickinson, and A. Mankin, "DNS over Dedicated QUIC Connections," RFC 9250, May 2022.
- [4] C. Campo, C. Garcia-Rubio, A. Jimenez-Berenguel, M. Moure-Garrido, F. Almenares, and D. Díaz-Sánchez, "Inferring mobile applications usage from DNS traffic," *Ad Hoc Networks*, vol. 163, p. 103601, 2024. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1570870524002129>
- [5] A. Jimenez-Berenguel, M. Moure-Garrido, C. Garcia-Rubio, and C. Campo, "Characterizing Mobile Applications Through Analysis of DNS Traffic," in *Proceedings of the Int'l ACM Symposium on Performance Evaluation of Wireless Ad Hoc, Sensor, & Ubiquitous Networks*, ser. PE-WASUN '23. New York, NY, USA: Association for Computing Machinery, 2023, p. 69–76. [Online]. Available: <https://doi.org/10.1145/3616394.3618268>
- [6] A. Jimenez-Berenguel, C. Gil, C. Garcia-Rubio, J. Forné, and C. Campo, "DNS Query Forgery: A Client-Side Defense Against Mobile App Traffic Profiling," *IEEE Access*, vol. 13, pp. 196 747–196 765, 2025.
- [7] X. Xiao, X. Zhou, Z. Yang, L. Yu, B. Zhang, Q. Liu, and X. Luo, "A comprehensive analysis of website fingerprinting defenses on Tor," *Computers & Security*, vol. 136, p. 103577, 2024.
- [8] M. Juárez, M. Imani, M. Perry, C. Díaz, and M. Wright, "Toward an Efficient Website Fingerprinting Defense," in *Computer Security – ESORICS 2016*, I. Askoxylakis, S. Ioannidis, S. Katsikas, and C. Meadows, Eds. Cham: Springer International Publishing, 2016, pp. 27–46.
- [9] J. Holland and N. Hopper, "Regulator: A straightforward website fingerprinting defense," *Proceedings on Privacy Enhancing Technologies*, vol. 2022, no. 2, pp. 344–362, Apr. 2022.
- [10] J. Gong and T. Wang, "Zero-delay Lightweight Defenses against Website Fingerprinting," in *29th USENIX Security Symposium (USENIX Security 20)*. USENIX Association, Aug. 2020, pp. 717–734. [Online]. Available: <https://www.usenix.org/conference/usenixsecurity20/presentation/gong>
- [11] D. Morozovič, M. Konopa, and J. Fesl, "DNS fingerprint based on user activity," *Scientific Reports*, vol. 16, 2026.
- [12] M. Singh, M. Singh, and S. Kaur, "Detecting bot-infected machines using DNS fingerprinting," *Digital Investigation*, vol. 28, pp. 14–33, 2019.
- [13] C.-I. Fan, C.-H. Shie, C.-M. Hsu, T. Ban, T. Morikawa, and T. Takahashi, "Iot botnet detection based on the behaviors of dns queries," in *2022 IEEE Conference on Dependable and Secure Computing (DSC)*, June 2022, pp. 1–7.
- [14] H. Vranken and H. Alizadeh, "Detection of DGA-Generated Domain Names with TF-IDF," *Electronics*, vol. 11, no. 3, 2022.
- [15] K. Wu, Y. Zhang, and T. Yin, "FTPB: A Three-Stage DNS Tunnel Detection Method Based on Character Feature Extraction," in *2020 IEEE 19th International Conference on Trust, Security and Privacy in Computing and Communications (TrustCom)*, Dec 2020, pp. 250–258.
- [16] R. Perdisci, T. Papastergiou, O. Alrawi, and M. Antonakakis, "IoTfinder: Efficient Large-Scale Identification of IoT Devices via Passive DNS Traffic Analysis," in *2020 IEEE European Symposium on Security and Privacy (EuroS&P)*, Sep. 2020, pp. 474–489.
- [17] D. Chang, J. Q. Chen, Z. Li, and X. Li, "Hide and Seek: Revisiting DNS-based User Tracking," in *2022 IEEE 7th European Symposium on Security and Privacy (EuroS&P)*, June 2022, pp. 188–205.
- [18] X. Cai, R. Nithyanand, T. Wang, R. Johnson, and I. Goldberg, "A Systematic Approach to Developing and Evaluating Website Fingerprinting Defenses," in *Proceedings of the 2014 ACM SIGSAC Conference on Computer and Communications Security*, ser. CCS '14. New York, NY, USA: Association for Computing Machinery, 2014, p. 227–238. [Online]. Available: <https://doi.org/10.1145/2660267.2660362>
- [19] K. P. Dyer, S. E. Coull, T. Ristenpart, and T. Shrimpton, "Peek-a-Boo, I Still See You: Why Efficient Traffic Analysis Countermeasures Fail," in *2012 IEEE Symposium on Security and Privacy*, May 2012, pp. 332–346.
- [20] T. Wang and I. Goldberg, "Walkie-Talkie: An efficient defense against passive website fingerprinting attacks," in *26th USENIX Security Symposium (USENIX Security 17)*. Vancouver, BC: USENIX Association, Aug. 2017, pp. 1375–1390. [Online]. Available: <https://www.usenix.org/conference/usenixsecurity17/technical-sessions/presentation/wang-tao>
- [21] P. Sirinam, M. Imani, M. Juárez, and M. Wright, "Deep Fingerprinting: Undermining Website Fingerprinting Defenses with Deep Learning," in *Proceedings of the 2018 ACM SIGSAC Conference on Computer and Communications Security*, ser. CCS '18. New York, NY, USA: Association for Computing Machinery, 2018, p. 1928–1943. [Online]. Available: <https://doi.org/10.1145/3243734.3243768>
- [22] Y. Wang, Y. Wang, J.-J. Huang, and Y. Chen, "TBP: Tree structure Burst-sequence Padding Defense Against Website Fingerprinting," in *2023 IEEE International Performance, Computing, and Communications Conference (IPCCC)*, Nov 2023, pp. 99–108.
- [23] M. S. Rahman, M. Imani, N. Mathews, and M. Wright, "Mockingbird: Defending Against Deep-Learning-Based Website Fingerprinting Attacks With Adversarial Traces," *IEEE Transactions on Information Forensics and Security*, vol. 16, pp. 1594–1609, 2021.
- [24] C. Hou, G. Gou, J. Shi, P. Fu, and G. Xiong, "WF-GAN: Fighting Back Against Website Fingerprinting Attack Using Adversarial Learning," in *2020 IEEE Symposium on Computers and Communications (ISCC)*, July 2020, pp. 1–7.
- [25] J. Gong, W. Zhang, C. Zhang, and T. Wang, "Surakav: Generating Realistic Traces for a Strong Website Fingerprinting Defense," in *2022 IEEE Symposium on Security and Privacy (SP)*, May 2022, pp. 1558–1573.
- [26] J. Gong, W. Zhang, C. Zhang, and T. Wang, "WFDefProxy: Real World Implementation and Evaluation of Website Fingerprinting Defenses," *IEEE Transactions on Information Forensics and Security*, vol. 19, pp. 1357–1371, 2024.
- [27] J. Ren, D. J. Dubois, and D. Choffnes, "An international view of privacy risks for mobile apps," Online, 2019. [Online]. Available: <https://recon.meddle.mobi/papers/cross-market.pdf>
- [28] D. Mankowski, T. Wiggers, and V. Moonsamy, "TLS → Post-Quantum TLS: Inspecting the TLS landscape for PQC adoption on Android," in *2023 IEEE European Symposium on Security and Privacy Workshops (EuroS&PW)*, July 2023, pp. 526–538.
- [29] T.-D. Pham, T.-L. Ho, T. Truong-Huu, T.-D. Cao, and H.-L. Truong, "MAppGraph: Mobile-app classification on encrypted network traffic using deep graph convolution neural networks," in *Proceedings of the 37th Annual Computer Security Applications Conference*, ser. ACSAC '21. New York, NY, USA: Tan Tao University, Singapore Institute of Technology, Aalto University, 2021, p. 1025–1038. [Online]. Available: <https://doi.org/10.1145/3485832.3485925>
- [30] E. Kinneer, P. McManus, T. Pauly, T. Verma, and C. A. Wood, "Oblivious DNS over HTTPS," RFC 9230, Jun. 2022.

How Worrying Are Privacy Attacks Against Machine Learning? (Extended Abstract)

Josep Domingo-Ferrer

Universitat Rovira i Virgili

Department of Computer Engineering and Mathematics

CYBERCAT-Center for Cybersecurity Research of Catalonia

COMSCiam-Center for Computational Science and Applied Mathematics

Av. Països Catalans 26, 43007 Tarragona, Catalonia

E-mail josep.domingo@urv.cat

Abstract—In several jurisdictions, the regulatory framework on the release and sharing of personal data is being extended to machine learning (ML). The implicit assumption is that disclosing a trained ML model entails a privacy risk for any personal data used in training comparable to directly releasing those data. However, given a trained model, it is necessary to mount a *privacy attack* to make inferences on the training data. In this concept paper, we examine the main families of privacy attacks against predictive and generative ML, including membership inference attacks (MIAs), property inference attacks, and reconstruction attacks. Our discussion shows that most of these attacks seem less effective in the real world than what a *prima facie* interpretation of the related literature could suggest.

Index Terms—Machine learning, privacy, predictive models, generative models, membership inference attacks, property inference attacks, reconstruction attacks

Contribution type: *Published research.* This is a summary of J. Domingo-Ferrer, “How worrying are privacy attacks against machine learning?”, in *Data Privacy Management - DPM 2025*, within *30th European Symposium on Research in Computer Security*, LNCS, Springer.

I. INTRODUCTION

The main regulations in the EU that affect the development of AI are the General Data Protection Regulation (GDPR) and the EU Artificial Intelligence Act. Furthermore, the EU has announced the implementation of a Code of Practice for general purpose AI models [7]. No similar regulations are in force in the other two major economic blocs (USA, China).

Given the above situation and the fact that Chinese regulations on AI are more focused on protecting the government than the citizens from AI, the EU remains the world’s only major economic bloc committed to trustworthy AI. At the same time, the EU lags behind the USA and China from the AI technology point of view.

For the European AI industry to be able to catch up with its competitors in spite of a more strict regulatory framework, it is extremely important to make sure that regulations are not more strict than required to preserve the values of trustworthy AI, and in particular privacy. Unfortunately, this does not seem to be the case today. The EU regulations assume that *any* disclosure might cause a breach of privacy. In particular, there is an implicit assumption that the disclosure of a trained machine learning (ML) model entails a privacy risk for any personal data used in training comparable to the direct release of those data.

This overcautious approach is probably due to the rushed inclusion of generative AI in the legal texts, and it may lead to adopting countermeasures that increase the training overhead and decrease the accuracy of models. For example, differential privacy [5] is a commonly proposed countermeasure that can cause two-digit drops in model accuracy if applied with meaningful privacy parameters. This seriously compromises the performance and competitiveness of the models and might be *unnecessary* if risks can be demonstrated to be overestimated.

There is a fundamental privacy difference between releasing an ML model trained on personal data and directly releasing those training data. If only the trained ML model is disclosed, it is necessary to mount a *privacy attack* to make any inferences on the training data. In this paper, we discuss how effective the privacy attacks proposed in the literature against predictive and generative ML are in *real-world* conditions. Specifically, we cover membership inference attacks (MIAs), property inference attacks, and reconstruction attacks.

II. MEMBERSHIP INFERENCE ATTACKS

Membership inference attacks (MIAs) are the most common attack employed to assess the privacy of training data in machine learning. Two properties of the training data are simultaneously required for the MIA to allow unequivocal inferences:

- *Exhaustivity.* Unless the training data were an exhaustive sample of a population (which is very rare), membership inferences cannot be unequivocal. In other words, the membership revealed by an MIA to a non-exhaustive training set could be plausibly denied. On the other hand, if the training data set is exhaustive, membership is trivial and no MIA is really needed: every existing record is a member.
- *Non-diversity of unknown attributes.* Since inferring membership to an exhaustive sample is not a real discovery, let us examine whether at least it can bring attribute disclosure. If there are several member records matching the attribute values known to the attacker, and the unknown attributes among those records differ significantly, then no attribute disclosure occurs.

In fact, it is relatively easy for a model trainer to benefit from the above two protections against MIAs. It is easier to get non-exhaustive than exhaustive training data, and the latter can always be made non-exhaustive by sampling. On the other

hand, confidential attributes are naturally diverse and, if there is not enough diversity, it can be enforced by l -diversity or t -closeness.

Beyond studying the generic limitations of MIAs due to the data used to train the attacked ML models, one can examine the specifics of the model under attack and the attack method. In [6], the effectiveness of MIAs on discriminative machine learning (ML) models is assessed by checking four requirements: i) the model under attack should not be overfitted (overfitted models are an easy MIA target, but they do not generalize well in their main tasks); ii) the model under attack must have a competitive test accuracy (attacking an uncompetitive model is not very interesting); iii) the attack must yield reliable membership inference; iv) and the attack must have a reasonable computational cost. Among the many MIA attacks reviewed by these authors, none satisfies these four requirements simultaneously. Regarding MIAs on generative ML, it has been shown in [4] that MIAs on LLMs are hardly better than random guessing.

III. PROPERTY INFERENCE ATTACKS

A property inference attack [1] seeks to infer a sensitive *global* property of the data set used to train an ML model, that is, a property P of the data set that the model producer did not intend to share.

From the point of view of privacy, property inference attacks do not entail a significant risk, because *they aim to infer a general property of the training data set rather than a property specific to a particular target subject*. By way of illustration, an example of P mentioned in [1] is whether “Google traffic was used in the training data”.

Even if disclosing such a property was not intended by the model producer and may cause some embarrassment to them, the general nature of those properties can hardly disclose private attributes on any of the specific individuals whose data may have been used for training.

IV. RECONSTRUCTION ATTACKS

The problem of reconstructing the data set used to train an ML model bears some similarities to the database reconstruction problem [3]. (Partial) Reconstruction of training data is greatly facilitated if the model is overfitted because, in that case, it memorizes training data. Beyond being problematic for privacy, overfitting is also a great problem for utility, since overfitted models usually perform poorly at test/validation time. Hence, models used for production in the real world can be safely assumed not to be overfitted.

Regarding privacy, a good deal of the related literature use MIA-based metrics. There are two important factors that influence the success of MIAs: (i) whether the target points whose membership is to be inferred are outliers or not and (ii) how good the MIA techniques employed are.

Using MIAs to assess the effectiveness of reconstruction attacks may seem reasonable if the training data are tabular, although it can be very expensive (a MIA must be mounted for each potential value that can be a member). It must be taken into account that state-of-the-art MIAs offering the best membership detection, such as LiRA [2], require training several shadow models. Thus, each MIA incurs a substantial computation cost.

Furthermore, especially in generative ML, training data are often non-tabular. For example, they are unstructured text or multimedia. Clearly, for non-tabular training data such as images or unstructured text, mounting an MIA to test whether each potential image or each potential unstructured text was part of the training data set seems quite unaffordable.

If reconstruction based on MIAs is problematic for the reasons above, reconstruction without MIAs suffers from at least two weaknesses: (i) it requires access to gradients for gradient inversion and thus is not feasible if access to the model is just black-box; (ii) the attacker has no numerical criterion to find out whether reconstruction was successful, unless they have access to the actual training data (which is not realistic).

V. CONCLUSIONS

Our analysis casts doubts on the effectiveness of privacy attacks against ML in real-world conditions.

All in all, the current real-world privacy risks incurred by machine learning seem less serious than what is usually assumed in the literature. Therefore, privacy defenses that entail severe utility loss, such as differential privacy, may often be unnecessary. The good side of all this is that trustworthy machine learning may be easier to implement than assumed so far, at least with respect to privacy. This is good news for jurisdictions like the European Union that struggle to reconcile strong AI regulations with the competitiveness of their AI industry.

ACKNOWLEDGMENTS

This work was partly funded by the Centre International de Mathématiques et d’Informatique de Toulouse (CIMI), the Government of Catalonia (ICREA Acadèmia Prize to J. Domingo-Ferrer), MCIN/AEI under grant PID2024-157271NB-I00 “CLEARING-IT”, and INCIBE and European Union NextGenerationEU/PRTR (project “HERMES” and INCIBE-URV Cybersecurity Chair).

REFERENCES

- [1] Giuseppe Ateniese, Luigi V Mancini, Angelo Spognardi, Antonio Villani, Domenico Vitali, and Giovanni Felici. Hacking smart machines with smarter ones: How to extract meaningful data from machine learning classifiers. *International Journal of Security and Networks*, 10(3):137–150, 2015.
- [2] Nicholas Carlini, Steve Chien, Milad Nasr, Shuang Song, Andreas Terzis, and Florian Tramèr. Membership inference attacks from first principles. In *2022 IEEE symposium on security and privacy (SP)*, pages 1897–1914. IEEE, 2022.
- [3] Irit Dinur and Kobbi Nissim. Revealing information while preserving privacy. In *Proceedings of the twenty-second ACM SIGMOD-SIGACT-SIGART symposium on Principles of database systems*, pages 202–210, 2003.
- [4] Michael Duan, Anshuman Suri, Niloofar Mirehshgallah, Sewon Min, Weijia Shi, Luke Zettlemoyer, Yulia Tsvetkov, Yejin Choi, David Evans, and Hannaneh Hajishirzi. Do membership inference attacks work on large language models? *arXiv preprint arXiv:2402.07841*, 2024.
- [5] Cynthia Dwork, Frank McSherry, Kobbi Nissim, and Adam Smith. Calibrating noise to sensitivity in private data analysis. In *Theory of Cryptography: Third Theory of Cryptography Conference (TCC 2006)*, New York, NY, USA, March 4-7, 2006. *Proceedings 3*, pages 265–284. Springer, 2006.
- [6] Najeeb Jebreel, David Sánchez, and Josep Domingo-Ferrer. A critical review on the effectiveness and privacy threats of membership inference attacks. In *31st European Symposium on Research in Computer Security (ESORICS 2026)*. Springer, to appear.
- [7] European Union. General-purpose AI code of practice. <https://digital-strategy.ec.europa.eu/en/policies/contents-code-gpai>, 2025. (Accessed on April 6, 2026).

A summary of: Privacy-Preserving Feature Valuation in Vertical Federated Learning Using Shapley-CMI and PSI Permutation

Unai Laskurain

Electronics and Computing Department
Mondragon Unibertsitatea
Arrasate-Mondragón, España
unai.laskurain@alumni.mondragon.edu

Aitor Aguirre-Ortuzar

Electronics and Computing Department
Mondragon Unibertsitatea
Arrasate-Mondragón, España
aaguirre@mondragon.edu

Urko Zurutuza

Electronics and Computing Department
Mondragon Unibertsitatea
Arrasate-Mondragón, España
uzurutuza@mondragon.edu

Resumen—El Aprendizaje Federado (FL), es un paradigma de aprendizaje que permite entrenar un modelo a partir de datos de diferentes propietarios participantes. En el Aprendizaje Federado Vertical (VFL), donde cada participante posee diferentes características para los mismos usuarios, un desafío fundamental es evaluar la contribución de los datos de cada participante antes de entrenar un modelo. Para abordar esto, el método Shapley-CMI propone un enfoque basado en la teoría de la información utilizando la Información Mutua Condicional (CMI). Sin embargo, su formulación original carece de una implementación práctica que calcule permutaciones e intersecciones de forma segura. Este artículo presenta una novedosa implementación que preserva la privacidad para Shapley-CMI en VFL. Nuestro sistema introduce un servidor de Intersección Segura de Conjuntos (PSI) que realiza las permutaciones necesarias y calcula los tamaños de las intersecciones sobre grupos de identificadores encriptados y discretizados, sin intercambiar datos en crudo. Los resultados experimentales confirman la corrección y privacidad del sistema propuesto, demostrando su viabilidad para una estimación eficiente y segura en VFL.

Index Terms—Aprendizaje Federado Vertical, Valoración de Datos, Valor de Shapley, Información Mutua Condicional, Intersección Segura de Conjuntos.

Tipo de contribución: Investigación ya publicada (límite 2 páginas)

I. INTRODUCCIÓN

El Aprendizaje Federado (FL) [1] permite a múltiples propietarios de datos entrenar un modelo compartido sin revelar sus datos originales. Dentro de este paradigma, el Aprendizaje Federado Vertical (VFL) [2] se aplica cuando los participantes poseen diferentes espacios de características sobre el mismo conjunto de usuarios, en contraste con el escenario horizontal (HFL) [3].

Un reto crucial en VFL es evaluar de forma temprana la contribución de las características de cada participante al modelo final [4], evitando así el consumo innecesario de recursos computacionales y de red en partes que no aportan valor predictivo. Existen métodos de estimación basados en valores de Shapley mediante la Información Mutua Condicional (CMI) [5], conocidos como Shapley-CMI, que requieren un servidor de Intersección Segura de Conjuntos (PSI). Sin embargo, este servidor no puede generar las permutaciones requeridas de forma autónoma y privada. Para superarlo, proponemos un método donde las partes discretizan sus valores y agrupan sus

identificadores (IDs) encriptados mediante HMAC-SHA256 antes de enviarlos al PSI, asegurando la confidencialidad total del proceso desde su origen [6].

II. TRABAJOS RELACIONADOS

La valoración de datos se ha estudiado ampliamente, aunque mayoritariamente en HFL [7], [8]. En VFL, gran parte de las aproximaciones requieren modelos ya entrenados [9]–[13], impidiendo su uso temprano. Aunque existen técnicas aplicables en fases previas [14], [15], no abordan adecuadamente las correlaciones cruzadas o la redundancia. El uso de CMI para aproximar valores de Shapley [4] evita depender de un modelo apoyándose en servidores PSI [16], pero presenta graves dificultades operativas para generar permutaciones de forma privada, una brecha que nuestra arquitectura resuelve directamente y de forma eficiente.

III. METODOLOGÍA

La arquitectura propuesta conecta múltiples clientes (*task party* y *data parties*) con un único servidor central PSI, como ilustra la Fig. 1.




Figura 1. Arquitectura del sistema con servidor PSI.

III-A. Arquitectura del Sistema

Localmente, cada parte encripta sus IDs y discretiza los valores de sus características. Los conjuntos de IDs encriptados se transmiten al servidor PSI, el cual identifica a los usuarios comunes para asegurar que los cálculos operen solo

sobre datos compartidos. Este paso de alineación es vital para construir una base homogénea antes de evaluar cualquier métrica basada en la teoría de la información.

Seguidamente, el servidor crea permutaciones aleatorias del orden de las características. En el marco de los valores de Shapley, la relevancia de una variable no es absoluta, sino que depende directamente de qué otras variables ya han sido evaluadas junto a ella. Por tanto, estas permutaciones representan diferentes secuencias teóricas en las que las características se van integrando de forma incremental al modelo. A medida que se construye cada secuencia, el servidor calcula el tamaño de las intersecciones PSI para las combinaciones de grupos resultantes. Este paso es fundamental porque permite ir simulando las contribuciones marginales de manera exhaustiva; en otras palabras, el sistema cuantifica la cantidad exacta de información nueva, única y no redundante que añade una característica particular justo en el momento de sumarse a un subconjunto de variables que le preceden en esa permutación. Finalmente, el servidor devuelve los tamaños de las intersecciones a las partes, quienes calculan localmente los valores CMI. Esta descentralización evita que el servidor central acceda a resultados numéricos derivados directamente de los datos en crudo

III-B. Métrica de Valoración

La métrica se asienta en el marco Shapley-CMI. El valor de Shapley de una característica d , denotado ϕ_d , mide su contribución marginal a la información predictiva sobre la variable objetivo Y_t :

$$\phi_d = \sum_{D \subseteq \mathcal{D} \setminus \{d\}} \frac{|D|!(|\mathcal{D}| - |D| - 1)!}{|\mathcal{D}|!} I(X_d; Y_t | X_D X_t) \quad (1)$$

El término $I(X_d; Y_t | X_D X_t)$ representa el CMI entre d y Y_t , dadas las características previas. Mediante el conteo de co-ocurrencias de valores discretizados, se logra integrar teoría de juegos e información preservando la privacidad en todo momento.

IV. CONCLUSIONES

Presentamos una implementación segura y escalable de Shapley-CMI para VFL, que no requiere entrenar modelos previamente. Las contribuciones se centran en preservar la privacidad mediante encriptación (HMAC-SHA256) y lograr eficiencia mediante la discretización y orquestación segura del protocolo PSI. Los resultados validan que el sistema computa las permutaciones necesarias para generar estimaciones robustas de las variables, reafirmando la viabilidad de integrar privacidad en etapas analíticas iniciales. Como línea de trabajo futuro, se propone explorar la integración de este esquema con técnicas de mitigación de ataques adversarios para fortalecer aún más la robustez del entorno colaborativo.

AGRADECIMIENTOS

Aitor Aguirre-Ortuzar y Urko Zurutuza forman parte del grupo de investigación Sistemas Inteligentes para Sistemas Industriales de Mondragon Unibertsitatea (IT1870-26), financiado por el Departamento de Ciencia, Universidades e Innovación del Gobierno Vasco, el cual ha financiado parcialmente este trabajo.

REFERENCIAS

- [1] C. Zhang, Y. Xie, H. Bai, B. Yu, W. Li, and Y. Gao, "A survey on federated learning," *Knowledge-Based Systems*, vol. 216, p. 106775, Mar. 2021. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0950705121000381>
- [2] Y. Liu, Y. Kang, T. Zou, Y. Pu, Y. He, X. Ye, Y. Ouyang, Y.-Q. Zhang, and Q. Yang, "Vertical Federated Learning: Concepts, Advances, and Challenges," *IEEE Transactions on Knowledge and Data Engineering*, vol. 36, no. 7, pp. 3615–3634, Jul. 2024. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/10415268>
- [3] Q. Yang, Y. Liu, Y. Cheng, Y. Kang, T. Chen, and H. Yu, "Horizontal Federated Learning," in *Federated Learning*, Q. Yang, Y. Liu, Y. Cheng, Y. Kang, T. Chen, and H. Yu, Eds. Cham: Springer International Publishing, 2020, pp. 49–67. [Online]. Available: https://doi.org/10.1007/978-3-031-01585-4_4
- [4] X. Han, L. Wang, and J. Wu, *Data Valuation for Vertical Federated Learning: An Information-Theoretic Approach*, Dec. 2021.
- [5] S. Kamara, P. Mohassel, M. Raykova, and S. Sadeghian, "Scaling Private Set Intersection to Billion-Element Sets," in *Financial Cryptography and Data Security*, N. Christin and R. Safavi-Naini, Eds. Berlin, Heidelberg: Springer Berlin Heidelberg, 2014, vol. 8437, pp. 195–215, series Title: Lecture Notes in Computer Science. [Online]. Available: http://link.springer.com/10.1007/978-3-662-45472-5_13
- [6] U. Laskurain, A. Aguirre-Ortuzar, and U. Zurutuza, "Privacy-preserving feature valuation in vertical federated learning using shapley-cmi and psi permutation," in *2025 3rd International Conference on Federated Learning Technologies and Applications (FLTA)*, 2025, pp. 86–92.
- [7] J. Zhao, X. Zhu, J. Wang, and J. Xiao, "Efficient Client Contribution Evaluation for Horizontal Federated Learning," in *ICASSP 2021 - 2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Jun. 2021, pp. 3060–3064, iSSN: 2379-190X. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/9413377>
- [8] Z. Fan, H. Fang, Z. Zhou, J. Pei, M. P. Friedlander, C. Liu, and Y. Zhang, "Improving Fairness for Data Valuation in Horizontal Federated Learning," in *2022 IEEE 38th International Conference on Data Engineering (ICDE)*, May 2022, pp. 2440–2453, arXiv:2109.09046 [cs]. [Online]. Available: <http://arxiv.org/abs/2109.09046>
- [9] Z. Fan, H. Fang, Z. Zhou, J. Pei, M. P. Friedlander, and Y. Zhang, "Fair and efficient contribution valuation for vertical federated learning," Jan. 2022, arXiv:2201.02658 [cs]. [Online]. Available: <http://arxiv.org/abs/2201.02658>
- [10] J. Jiang, L. Burkhalter, F. Fu, B. Ding, B. Du, A. Hithnawi, B. Li, and C. Zhang, "VF-PS: How to Select Important Participants in Vertical Federated Learning, Efficiently and Securely?" *Advances in Neural Information Processing Systems*, vol. 35, pp. 2088–2101, Dec. 2022. [Online]. Available: https://proceedings.neurips.cc/paper_files/paper/2022/hash/0e1a2388cd2f78069f4d048d935cb218-Abstract-Conference.html
- [11] A. Li, H. Peng, L. Zhang, J. Huang, Q. Guo, H. Yu, and Y. Liu, "FedSDG-FS: Efficient and Secure Feature Selection for Vertical Federated Learning," in *IEEE INFOCOM 2023 - IEEE Conference on Computer Communications*, May 2023, pp. 1–10, iSSN: 2641-9874. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/10228895>
- [12] T. Song, Y. Tong, and S. Wei, "Profit Allocation for Federated Learning," in *2019 IEEE International Conference on Big Data (Big Data)*, Dec. 2019, pp. 2577–2586. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/9006327>
- [13] Y. Cui, C.-j. Huang, Y. Zhang, L. Wang, L. Fan, X. Zhou, and Q. Yang, "A Survey on Contribution Evaluation in Vertical Federated Learning," May 2024, arXiv:2405.02364 [cs]. [Online]. Available: <http://arxiv.org/abs/2405.02364>
- [14] A. Khan, M. t. Thij, G. Tang, and A. Wilbik, "VFL-RPS: Relevant Participant Selection in Vertical Federated Learning," Feb. 2025, arXiv:2502.14375 [cs]. [Online]. Available: <http://arxiv.org/abs/2502.14375>
- [15] X. Li, R. Dowsley, and M. D. Cock, "Privacy-Preserving Feature Selection with Secure Multiparty Computation," in *Proceedings of the 38th International Conference on Machine Learning*. PMLR, Jul. 2021, pp. 6326–6336, iSSN: 2640-3498. [Online]. Available: <https://proceedings.mlr.press/v139/li21e.html>
- [16] C. Dong, L. Chen, J. Camenisch, and G. Russello, "Fair Private Set Intersection with a Semi-trusted Arbitrator," in *Data and Applications Security and Privacy XXVII*, L. Wang and B. Shafiq, Eds. Berlin, Heidelberg: Springer, 2013, pp. 128–144.

Zaguik: Zero-Knowledge Attestation for Privacy-Preserving LLM Governance

Jan Aguiló Plana
Universitat Pompeu Fabra
Carrer de Roc Boronat, 138, Barcelona
jan.aguilo01@estudiant.upf.edu

Vanesa Daza
Universitat Pompeu Fabra
Carrer de Roc Boronat, 138, Barcelona
vanesa.daza@upf.edu

Abstract—Regulators increasingly require evidence-backed assurances about how AI systems handle sensitive information. We present Zaguik, a privacy-preserving attestation pipeline that proves, in zero knowledge, that a large language model (LLM) response passed a personally identifiable information (PII) filter, without revealing either the response text or the filtering model. The system generates an LLM response, applies a PII detection policy, and produces a zk-SNARK using EzKL over the detector inference. The proof exposes only a public commitment (a hash) to the attested output prefix, associating the proof with the encoded portion of the delivered response via a protocol-level hash commitment while keeping its contents private. We provide a runnable reference implementation, discuss practical setup requirements and ONNX compatibility constraints, and outline how such proofs can support GDPR-aligned auditing and transparent AI governance.

I. INTRODUCTION

Artificial intelligence (AI) systems that process personal data are increasingly subject to enforceable obligations beyond voluntary transparency pledges. Regulations such as the European Union’s General Data Protection Regulation (GDPR) and emerging AI acts require evidence-backed assurances about how systems handle sensitive information, comply with safety requirements, and respect data-subject rights. For large language models (LLMs) deployed in customer-facing or regulated settings, demonstrating that outputs do not leak personally identifiable information (PII) is both a legal necessity and a trust requirement. Auditors and regulators need not only policies on paper but verifiable guarantees that those policies are actually applied in production.

Today, verifying that a provider applies a PII filter to LLM outputs typically requires the auditor to trust the provider’s claims or to inspect the outputs and the filtering logic directly. If the auditor sees the raw outputs, privacy is compromised; if the provider must disclose the filtering model or its parameters, intellectual property and competitive concerns arise. This tension leaves a gap: there is no cryptographically sound way to prove that a given output was filtered for PII without revealing either the output or the internals of the filter. Zero-knowledge proofs (ZKPs) address this need by allowing one party (the prover) to convince another (the verifier) that a statement is true without revealing the underlying data or computation. Applied to AI pipelines, ZKPs can attest that a specific computation was performed (e.g., that a PII filter was applied and that its result indicated no PII) while keeping the model and the actual text private.

In this work we describe and implement Zaguik, a system that produces such a verifiable, privacy-preserving attestation

for LLM outputs. The pipeline works as follows: (1) an LLM generates a response to a user prompt; (2) a PII filter (in our reference implementation, a regex-based detector) is applied to the output; (3) if the output passes the filter, a SHA256 hash of the output is computed and the output is encoded as input to a circuit; (4) a zk-SNARK proof is generated using EzKL, attesting that the certified circuit was executed on the encoded output prefix and that it returned a `PASS` result; (5) any verifier holding the proof and the published hash commitment can confirm correct circuit execution over the attested prefix without seeing the text or filter internals. The proof thus attests correct execution of the circuit over the encoded prefix, while the hash commitment associates the attestation with a specific output at the protocol level. This approach illustrates how cryptographic attestation can support transparent AI governance: compliance and audit can be based on verifiable proofs rather than on trust alone, and both user privacy and provider confidentiality can be preserved. We provide a runnable reference implementation and discuss practical considerations.

II. RELATED WORK

A. Zero-Knowledge Proof Systems

Zero-knowledge proof systems such as Groth16 [1], PLONK [2], and related zk-SNARK constructions provide succinct and efficiently verifiable proofs of correct computation over arithmetic circuits. These systems allow a prover to convince a verifier that a computation was executed correctly without revealing private inputs.

More recently, practical toolchains such as libsnark [3], Halo2 [4], and EzKL [5] have enabled developers to compile high-level programs and machine learning models into circuits suitable for zk-SNARK proving.

However, these works focus on the cryptographic machinery for proving circuit execution correctness. They do not address the governance question of how such proofs can be used to attest enforcement of content filtering policies over LLM outputs without revealing those outputs.

B. Zero-Knowledge Machine Learning (ZKML)

Zero-knowledge machine learning focuses on proving correct execution of machine learning inference without revealing private inputs. zkCNN [6] demonstrates how convolutional neural network predictions and accuracy can be verified in zero knowledge by expressing inference as arithmetic circuits.

Similarly, vCNN [7] presents a framework for generating zk-SNARK proofs that certify correct execution of convolutional neural network inference.

These works address inference correctness: proving that a model’s output was computed faithfully according to fixed parameters. In contrast, our work does not aim to prove correct execution of the LLM itself. Instead, we focus on attesting enforcement of a post-generation filtering policy over LLM outputs. To our knowledge, prior ZKML research does not address governance-level attestation of output filtering for generative models, where the goal is not to prove the model computation but to prove that a compliance constraint was applied to the generated output.

C. Privacy-Preserving Machine Learning and Inference

Research in privacy-preserving machine learning includes techniques such as secure multiparty computation [8], homomorphic encryption for neural network inference [9], [10], and confidential computing enclaves.

These approaches focus on protecting either model parameters or user inputs during inference. For example, homomorphic encryption allows inference over encrypted data without revealing the input, while secure multiparty computation distributes trust across multiple parties.

Our work differs in focus: rather than protecting model inputs or parameters, we aim to protect the model output while still enabling verifiable policy enforcement. The output remains private, yet a verifier can be assured that a specified constraint was checked.

D. AI Auditing, Transparency, and Governance

AI governance frameworks emphasize auditing, transparency, and accountability. Model cards [11], datasheets for datasets [12], and regulatory frameworks such as the EU AI Act propose documentation-based or process-based accountability.

In practice, auditing of deployed systems typically requires access to logs, outputs, or internal documentation. Such approaches rely on institutional trust and do not provide cryptographic guarantees of enforcement at runtime.

Recent discussions in AI safety research have proposed verifiable AI or cryptographic attestation mechanisms, but concrete implementations for generative output filtering remain limited.

Our work contributes a concrete mechanism for cryptographically attesting that a filtering policy was executed on a specific LLM output, without revealing that output to the verifier.

E. PII Detection and Content Moderation

Personal data detection is commonly performed using rule-based systems (regex patterns), named entity recognition models, or hybrid approaches [13]. Production systems for content moderation rely on deterministic filters, ML classifiers, and policy enforcement pipelines.

However, these systems provide enforcement but not verifiability. An external auditor must either trust the system operator or inspect outputs directly. To our knowledge, prior work on PII filtering does not provide a mechanism for cryptographically proving that filtering was applied to a given output without revealing the output itself.

F. Positioning Statement

To our knowledge, no prior work combines zero-knowledge proofs with LLM output filtering to provide privacy-preserving attestation of policy enforcement. Existing zk-SNARK and ZKML systems enable proving correct circuit execution, but they do not address governance-level questions of output compliance. Conversely, AI auditing and moderation systems enforce policies but lack cryptographic verifiability.

Our work occupies the intersection of these domains: we demonstrate a practical prototype that attests enforcement of an output constraint over LLM-generated text while preserving output confidentiality.

III. METHODOLOGY

The core contribution of this work is the *cryptographic attestation pipeline*: we show how to produce a zk-SNARK proof that a given string was passed through a certified check, with the proof bound to a commitment to the output and with no disclosure of the text or the checker’s internals. The PII filter is the policy we attest to; its design is deliberately simple so that the focus remains on the proof system. Below we describe the architecture, the filter used in the current implementation, the encoding of outputs for the circuit, the proof system and visibility semantics, and the setup, proof, and verification procedures.

A. System Overview

The pipeline has two phases: a *filtering phase* and a *proof phase*. In the filtering phase, a user prompt is answered by an LLM (in our implementation we use DistilGPT-2); the response is then checked by a PII detector. Only if the detector reports that the text contains no PII do we enter the proof phase. There we encode the (clean) output as input to a circuit that models the same filtering logic, generate a zk-SNARK proof over that circuit using EzKL, and output a proof published together with a public commitment (hash) of the attested output prefix. A verifier receiving the proof and the commitment can check that the certified circuit was correctly executed on the encoded prefix, without learning the text or the filter parameters. The LLM itself is out of scope of the proof: we attest only that a given string was passed through the certified PII filter and passed. The end-to-end workflow is illustrated in Fig. 1.




Figure 1. Zaguik’s end-to-end workflow: from user prompt and LLM response through PII filtering to proof generation and verification.

B. zk-SNARK Preliminaries

A zk-SNARK (zero-knowledge succinct non-interactive argument of knowledge) is a proof system for NP relations of the form $R(x, w)$, where x is public input and w is a private witness. The prover convinces the verifier that there exists a witness w such that $R(x, w) = 1$, without revealing w . A zk-SNARK consists of three algorithms: *Setup*, which generates public parameters and keys for a fixed circuit; *Prove*, which produces a proof given the public input and private witness; and *Verify*, which checks the proof using only public data.

In our setting, the relation corresponds to correct execution of the certified circuit C on a private encoded input. The public instance consists of the circuit output (indicating pass/fail) together with protocol-level commitments. The private witness consists of the encoded output prefix and internal intermediate values required for circuit execution. The proof establishes that there exists a witness such that the circuit output equals “pass”, without revealing the encoded text itself.

C. Formal Statement and Security Model

We formally define what is proven by the zk-SNARK and clarify the distinction between circuit-level guarantees and protocol-level commitments.

a) *Notation*: Let $y \in \{0, 1\}^*$ denote the full output string generated by the LLM. Let L be a fixed encoding length in bytes. Let y_L denote the prefix of y consisting of its first L UTF-8 bytes (or the full string if $|y| \leq L$). Let $\text{Enc}_L(y_L)$ denote the byte-level encoding of y_L , truncated or zero-padded to length L . Let $H(\cdot)$ be a cryptographic hash function (SHA256 in our implementation). Let C be the certified arithmetic circuit implementing the circuit-level filtering policy.

b) *Public Instance and Witness*: The zk-SNARK proof distinguishes between public data and private witness.

- **Public instance**:
 - The public circuit output $o \in \{0, 1\}$ indicating PASS ($o = 1$) or FAIL.
- **Private witness**:
 - The encoded prefix $x = \text{Enc}_L(y_L)$.
 - The internal witness values required to execute circuit C .

The verification key and structured reference string are public system parameters provided to the verifier but are not part of the public instance of a specific proof.

c) *Circuit Statement*: The zk-SNARK proves the following NP statement:

$$\exists x \text{ such that } C(x) = 1.$$

That is, the prover demonstrates knowledge of an input x for which the certified circuit C evaluates to PASS. The circuit itself operates only on the encoded prefix x and does not receive the full string y .

d) *Protocol-Level Commitment*: Separately from the circuit, the prover computes a public commitment

$$h = H(y_L),$$

which binds the attestation to the encoded prefix y_L . The hash value h is published alongside the proof so that external

parties can associate the attestation with a specific output prefix.

Importantly, the equality $H(y_L) = h$ is not verified inside the arithmetic circuit. The binding between the public commitment h and the private witness x relies on the prover computing both from the same y_L prior to proof generation. Thus, the SNARK guarantees correct execution of $C(x)$, while the hash commitment operates at the protocol level.

e) *Security Model*: Under the standard soundness guarantees of zk-SNARKs, no probabilistic polynomial-time adversary can produce a valid proof for $C(x) = 1$ without knowing a witness x satisfying that relation. Zero-knowledge ensures that no information about x beyond the truth of the statement is revealed.

However, because the hash commitment is not enforced inside the circuit, the binding between h and x holds under an honest-prover assumption. A malicious prover could, in principle, produce a proof for some x while publishing an unrelated hash value h . Strengthening this binding would require verifying the hash inside the circuit or using a SNARK-friendly hash function within C .

We assume a standard adversarial model in which the prover may be malicious and the verifier is honest and follows the verification algorithm. Under the soundness property of zk-SNARKs, no probabilistic polynomial-time adversary can produce a valid proof for $C(x) = 1$ without knowledge of a witness x satisfying that relation. Zero-knowledge guarantees that the proof reveals no information about x beyond the validity of the statement.

The binding between the public commitment h and the private witness x is enforced at the protocol level and therefore holds under an honest-prover assumption. A malicious prover could, in principle, generate a valid proof for some x while publishing an unrelated hash value h . Preventing this would require incorporating hash verification inside the arithmetic circuit.

f) *Scope of the Guarantee*: The proof guarantees correct execution of the certified circuit C on an encoded prefix x . If $|y| \leq L$, the entire output is attested; otherwise, only the first L bytes are covered by the guarantee. The system does not prove semantic adequacy of the filtering policy, nor does it make claims about the internal behavior of the LLM. The guarantee is limited to enforcement integrity of the circuit-level constraint over the committed prefix.

D. PII Filtering and Policy

We distinguish clearly between two components of the filtering pipeline: an operational PII detector used in plain execution, and a circuit-friendly policy used for zero-knowledge attestation.

First, the system applies a regex-based PII filter in plain execution. This detector searches for structured patterns such as email addresses, phone numbers, identification numbers, and other commonly formatted personal data. Its role is operational: it acts as a gating mechanism, preventing obviously unsafe outputs from proceeding to the proof generation stage.

Second, for zero-knowledge attestation, we implement a separate, circuit-friendly policy as a small PyTorch module that is exported to ONNX and compiled into an arithmetic circuit using EzKL. This module operates at the byte level.

It takes as input a fixed-length normalized byte vector and counts occurrences of selected “suspicious” byte values (e.g., ‘@’). The circuit outputs a scalar count, and the policy is considered satisfied if this count is zero.

The zk-SNARK proof certifies correct execution of this ONNX-derived byte-level circuit and the fact that its output equals zero. It does not certify direct execution of the plain regex filter. The regex detector and the byte-counter circuit are separate mechanisms: the former provides practical PII detection in deployment, while the latter encodes a structurally checkable constraint that can be efficiently represented and verified within an arithmetic circuit.

It is therefore important to clarify the scope of equivalence. The proof guarantees only that the ONNX circuit was executed correctly on the encoded output. The correspondence between the plain regex-based filter and the byte-level circuit is a design choice, not a formally verified equivalence. The byte-counter policy can be interpreted as a conservative structural proxy for certain classes of PII indicators, but it does not capture the full semantic expressiveness of the regex detector. Establishing formal semantic equivalence between high-level filtering logic and its circuit representation remains an open research problem and is outside the scope of this prototype.

The attestation mechanism itself is policy-agnostic: any deterministic filtering rule that can be expressed as an ONNX model compatible with the proof backend can be certified in the same manner. In this work, the simplified byte-level policy serves to demonstrate the feasibility of zero-knowledge attestation for LLM output governance under current practical constraints.

E. Encoding and Circuit Input

The LLM output is a string. To feed it into the circuit we encode it in fixed-size form. We fix an upper bound L on the number of UTF-8 bytes (in our implementation $L = 2048$). The LLM generation process is configured so that attested outputs do not exceed L bytes. Therefore, for every attested output, the circuit receives the entire string.

We use a byte-level encoding: the UTF-8 representation of the string is zero-padded to length L if shorter. Each byte is normalized to $[0,1]$ by dividing by 255. The resulting vector has shape $[1, L]$ and is used as the single input tensor to the ONNX circuit.

The prefix y_L that passed the plain PII check is the portion encoded and fed into the circuit. If $|y| \leq L$, the entire output is attested; otherwise, only the first L bytes are covered. The proof is therefore tied to the encoded prefix rather than necessarily the full output.

Separately, we compute a SHA256 hash of the complete output string. This hash serves as a protocol-level identifier that associates the proof with a specific delivered response, under the assumption that the prover computes both from the same output. The hash is not used as circuit input; instead, it is provided as public data alongside the proof so that external parties can associate the attestation with a specific output.

F. Proof System and Visibility Semantics

We use EzKL to compile the ONNX model into an arithmetic circuit and to produce zk-SNARK proofs (succinct, non-interactive arguments of knowledge). The security and privacy

guarantees depend on how inputs, outputs, and parameters are exposed.

The encoded *input* is kept private as witness data. The verifier learns only the zk-SNARK proof and the public hash commitment: the prover commits to the encoded output string, and the verifier learns this commitment but not the underlying bytes, so the LLM response stays private while the attestation is associated with a specific output via a protocol-level commitment. The *output* of the circuit is made available to the verifier so they can check that it indicates “pass” (e.g., zero PII score). The filter *parameters* are fixed in the circuit and not revealed; the verifier only learns that the same certified circuit was executed. Together, these choices ensure that we prove that the certified circuit was executed on a private encoded prefix and returned `PASS`, while only a hash commitment to that prefix is revealed.

G. Setup and Proof Generation

Setup is performed once per circuit (e.g., per ONNX model and settings). The ONNX is used to generate the proof-system settings and to compile an arithmetic circuit; a KZG structured reference string (SRS) is required and can be obtained from a trusted source or generated locally for testing. With the compiled circuit and SRS, key generation yields a proving key and a verification key.

For each clean LLM output we wish to attest, we encode it as input data, compute the witness for the circuit, and run the prover to produce the final proof. The proof, the verification key, and (in deployment) the public commitment to the output are what the verifier needs.

H. Verification

Verification is deterministic: given the proof, the verification key, the settings, and the SRS, the verifier runs the verification algorithm and accepts if and only if the proof is valid. No secret data is required. If the verifier holds the published SHA256 hash, they can associate the proof with a specific output under the honest-prover assumption; note that this correspondence is not enforced inside the circuit.

I. Implementation and Reproducibility

Our reference implementation is in Python. The PII filter is regex-based in the current experiments. The cryptographic pipeline (regex-derived ONNX export, encoding, setup, proof generation, and verification) is implemented as a single scriptable workflow. The default configuration builds the small regex-derived ONNX, runs setup, and then generates and verifies proofs for a given text string. All steps are documented so that the pipeline can be reproduced and extended; integrating a more expressive PII model would require an ONNX export that is compatible with the proof system backend.

J. Experimental Setup

All experiments were conducted locally on a single machine with the following hardware and software configuration: a Snapdragon X 12-core X1E80100 CPU at 3.40 GHz (12 cores), 16 GB of RAM, running Windows 11 (64-bit). The implementation uses Python 3.13.3 and EzKL 22.2.1. No GPU acceleration was used; all proof generation and verification steps ran entirely on CPU.

The structured reference string (SRS) was generated locally using EzKL’s `gen_srs` function rather than retrieved from a remote trusted source. This choice is appropriate for a self-contained research prototype but would differ in a production deployment, where the SRS would typically be downloaded from a public trusted ceremony.

All experiments were run locally and sequentially, with no parallel execution across configurations. Each value of $L \in \{128, 256, 512, 1024, 2048\}$ was evaluated fifteen times ($n = 15$) using independently generated reference outputs from the same prompt and model. Each prompt was designed to produce a long output exceeding 2048 bytes in order to evaluate different circuit encoding sizes L . For each output, the pipeline was executed with

$$L \in \{128, 256, 512, 1024, 2048\}.$$

When $L < 2048$, only the prefix of length L bytes was encoded and attested. The mean values and sample statistics over the 15 runs are reported in Table II.

IV. RESULTS

Table I reports the one-time setup costs for the circuit with $L = 2048$. This includes settings generation, circuit compilation, structured reference string (SRS) generation, witness setup, and key generation. The total setup time was 102.44 seconds. SRS generation required 77.88 seconds, and key generation required 23.77 seconds. The remaining steps each took less than one second.

Table I
ONE-TIME SETUP COSTS (REGEX PII ONNX, $L = 2048$).

Step	Time (s)
Settings generation	0.14
Circuit compilation	0.02
SRS generation ^a	77.88
Witness (setup)	0.63
Key generation	23.77
Total	102.44

^aGenerated locally for testing; production deployments would download the SRS from a trusted source.

Table II presents proof size, proof generation time, witness computation time, and verification time for different values of L .

Proof size remains within a narrow range across all tested values of L , varying between 21 871 bytes ($L = 256$) and 21 929 bytes ($L = 2048$) in mean. No monotonic trend is observed. The minor variations are attributable to internal serialization differences and metadata encoding in the proof object, rather than structural changes in the underlying circuit.

Proof generation time exhibits high variance across all L values, with standard deviations ranging from $\pm 6 573$ ms ($L = 1024$) to $\pm 9 923$ ms ($L = 256$). Mean prove times range from approximately 14 840 ms ($L = 1024$) to 19 240 ms ($L = 256$). The measurements do not show a strictly monotonic pattern with respect to L , indicating that scheduling and memory effects dominate over circuit-size effects at this scale.

Witness computation time increases monotonically with L . The mean witness time is 54.31 ms for $L = 128$, 89.36 ms for $L = 256$, 150.55 ms for $L = 512$, 268.43 ms for $L = 1024$, and 540.82 ms for $L = 2048$.

Verification time remains broadly stable across all configurations, with means ranging from 168.73 ms ($L = 512$) to 200.85 ms ($L = 256$), though individual runs show occasional spikes reflected in the observed ranges.

V. DISCUSSION

A. Interpretation of Results

The experimental results show that zero-knowledge attestation can be executed end-to-end using a small circuit. Proof size remains nearly constant across all tested values of the circuit encoding size L , with means ranging from 21 871 bytes ($L = 256$) to 21 929 bytes ($L = 2048$), a variation of less than 0.3%. This confirms that proof size is determined by the circuit structure rather than by the amount of attested data.

Witness generation time grows monotonically with L (from 54.31 ms at $L = 128$ to 540.82 ms at $L = 2048$), reflecting the increase in the number of input commitments required as the encoding window grows. Proof generation time is the dominant cost and shows high variance across all L values (standard deviations of 6 573–9 923 ms), indicating sensitivity to local execution conditions (e.g., OS scheduling, memory pressure) rather than a strict functional dependence on L . Verification time remains broadly stable across all configurations (168–201 ms mean), consistent with the constant-size verifier computation of KZG-based SNARKs. This asymmetry implies that the computational burden is concentrated on the prover side, while verification remains comparatively lightweight.

The experiment also validates the prefix-attestation mechanism. For $L < 2048$ bytes (the full output length), only the first L bytes are encoded and attested. All 75 proof generation and verification attempts across all 15 runs and 5 values of L succeeded, confirming that the pipeline robustly supports prefix-based attestation. This flexibility allows the attested length to be tuned to circuit cost constraints while preserving verifiability, at the cost of limiting the guarantee to the committed prefix rather than the entire output.

B. Governance and Security Implications

The proposed pipeline illustrates a shift from trust-based enforcement to cryptographically verifiable enforcement. In conventional deployments, external parties must rely on the provider’s claims that safety or privacy filters are correctly applied to LLM outputs. Alternatively, verification requires disclosing either the generated output or the filtering logic, which may introduce privacy or intellectual property concerns.

Our approach enables a third party to verify that a specific, predefined circuit-based filtering policy was executed on a private encoded prefix, with the corresponding output identified via a protocol-level hash commitment under the honest-prover assumption, without revealing the output itself. The proof attests to correct execution of the circuit and to satisfaction of the encoded constraint, while the output remains private to the prover.

This mechanism supports a form of privacy-preserving auditability: verification can occur without access to the generated text. While it does not by itself ensure regulatory compliance, it provides a cryptographic primitive that may be integrated into governance frameworks where evidence of enforcement is required.

Table II

PROOF SIZE AND TIMINGS VS. CIRCUIT ENCODING SIZE L (15 INDEPENDENT RUNS; $n = 15$; REFERENCE OUTPUT = 2048 BYTES, PREFIX-TRUNCATED FOR $L < 2048$). EACH L BLOCK SHOWS MEAN, SAMPLE STANDARD DEVIATION ($\pm$ STD), AND OBSERVED RANGE [MIN, MAX].

L (bytes)		Proof size (bytes)	Proof gen. (ms)	Witness (ms)	Verify (ms)
128	Mean	21896.67	15240.07	54.31	195.64
	$\pm$ Std	± 27.33	± 8049.70	± 21.53	± 50.65
	[Min, Max]	[21850, 21944]	[10014.94, 33601.85]	[40.91, 128.50]	[150.74, 305.65]
256	Mean	21870.73	19240.44	89.36	200.85
	$\pm$ Std	± 39.03	± 9922.94	± 18.08	± 65.80
	[Min, Max]	[21822, 21966]	[11019.33, 32606.75]	[70.93, 134.03]	[149.94, 398.31]
512	Mean	21892.67	15944.43	150.55	168.73
	$\pm$ Std	± 33.82	± 7903.57	± 16.24	± 22.70
	[Min, Max]	[21835, 21954]	[10983.38, 33031.74]	[122.49, 183.49]	[140.98, 232.17]
1024	Mean	21893.07	14840.25	268.43	174.02
	$\pm$ Std	± 32.81	± 6573.20	± 20.57	± 34.71
	[Min, Max]	[21841, 21955]	[12137.78, 37693.64]	[237.38, 295.59]	[138.79, 260.96]
2048	Mean	21929.27	18219.90	540.82	182.45
	$\pm$ Std	± 37.22	± 9359.92	± 69.33	± 30.32
	[Min, Max]	[21867, 21991]	[12659.16, 43176.02]	[447.87, 704.70]	[152.73, 259.90]

The architecture is policy-agnostic at the circuit level. Any deterministic filtering rule that can be expressed as an ONNX model compatible with the proof system can, in principle, be attested using the same mechanism. In this work, we instantiate the approach with a byte-level structural policy derived from common PII indicators, but the framework can accommodate other circuit-representable post-processing constraints.

C. Limitations

Several limitations must be acknowledged.

First, the filtering policy attested within the zero-knowledge circuit is intentionally lightweight. The circuit implements a byte-level structural constraint designed to be efficiently representable as an arithmetic circuit. While sufficient to demonstrate feasibility, it does not reflect the complexity of modern neural PII detection systems. Attempts to integrate larger ONNX-based NER models revealed compatibility constraints within current ZKML tooling.

Second, the scope of the guarantee is bounded by the encoding length L . The circuit operates on a fixed-length byte vector, and only the first L bytes of an output are attested. When L is smaller than the full output length, the guarantee applies only to the encoded prefix. Although our experiments evaluate multiple values of L , extending coverage to arbitrarily long outputs would require increasing L , segmenting outputs into chunks with multiple proofs, or employing recursive proof composition.

Third, the system proves correct execution of the ONNX-derived circuit, not direct execution of the plain regex filter used in deployment. The regex-based detector and the circuit policy are separate components. While the circuit is designed to capture structural indicators of PII, no formal equivalence proof is provided between the plain filtering logic and its circuit representation.

Fourth, consistency between the public hash commitment and the encoded circuit input is enforced at the protocol level rather than inside the arithmetic circuit. The proof certifies correct execution of the circuit on a private input, but does not cryptographically enforce that the published hash corresponds to the exact same byte sequence used within the proof.

Strengthening this binding by verifying the hash inside the circuit would increase circuit complexity and proof cost.

Fifth, the system guarantees enforcement integrity of the encoded policy, not the semantic adequacy of the policy itself. A weak or incomplete detector may be correctly executed and proven. Zero-knowledge attestation ensures that a rule was applied, but does not evaluate whether the rule sufficiently captures all relevant forms of personal data.

Finally, production PII filtering policies are inherently dynamic: filters are frequently updated to address new threat patterns, evolving regulatory requirements, and emerging data types. The static nature of the arithmetic circuit means that any modification to the filtering policy requires recompiling the circuit, regenerating the proving and verification keys, and repeating the setup phase. This operational overhead may limit the practical applicability of the approach in deployment contexts where filtering logic changes frequently.

D. Towards Production Deployment

Deploying Zaguik in a real production environment would require addressing several practical requirements beyond the current prototype. We outline the key components of a minimal viable deployment.

First, the filtering circuit would need to be replaced with a more expressive policy. The current byte-level counter serves as a proof of concept but does not reflect the complexity of real PII detection. A lightweight neural NER model or a regex-derived circuit compatible with EzKL would provide stronger guarantees, provided ONNX compatibility constraints are satisfied.

Second, the structured reference string (SRS) would need to be obtained from a public trusted ceremony, such as the Perpetual Powers of Tau, rather than generated locally. Local SRS generation, as used in this prototype, does not provide the soundness guarantees required in an adversarial setting.

Third, proof generation time would need to be reduced significantly. The current 15–19 seconds per proof on CPU is not viable for high-throughput deployments. GPU acceleration, which can reduce proving time by one to two orders of magnitude, and optimized native implementations of EzKL would bring this cost into a practical range.

Fourth, proof generation should be decoupled from the real-time request pipeline through an asynchronous archi-

ture. Proofs would be generated in the background after each response is delivered, stored alongside a SHA256 hash commitment, and made available for audit on demand. This eliminates latency concerns for end users while preserving the audit trail for regulators.

Finally, a verifier interface would be needed to allow regulators and auditors to check proofs without requiring cryptographic expertise. A simple black-box tool accepting a proof and returning VALID or INVALID would make the system accessible to non-technical compliance stakeholders.

Taken together, these components define a realistic path from the current prototype to a deployable compliance primitive, particularly suited to regulated organizations operating their own private LLM infrastructure.

VI. CONCLUSIONS

We presented Zaguik, a privacy-preserving attestation pipeline that proves, in zero knowledge, that a circuit-encoded filtering policy was executed on an LLM output prefix and returned a PASS result without revealing the output itself. Using EzKL and a fixed ONNX-derived circuit, we evaluated the end-to-end proving pipeline under multiple encoding lengths. Empirical results show that proof size and verification time remain stable across tested configurations, while witness computation grows with the encoding length and proof generation remains the dominant cost.

Our prototype does not attempt to prove correct execution of the LLM itself, nor does it establish formal equivalence between deployment-time filtering logic and its circuit representation. Instead, it demonstrates that enforcement of a circuit-encoded policy over model outputs can be attested cryptographically while preserving output confidentiality.

These results suggest that zero-knowledge proofs can serve as a building block for verifiable enforcement mechanisms in AI systems. In particular, such attestations could be incorporated into workflows where language model outputs trigger downstream actions, interact with external tools, or are subject to compliance requirements. In these contexts, the ability to produce cryptographic evidence that a specific constraint was applied to a given output, without revealing that output, provides a new primitive for accountability.

Future work includes integrating more expressive filtering models within circuit constraints, strengthening the binding between public commitments and circuit inputs, scaling to longer outputs through chunking or recursive composition, and evaluating integration within broader AI governance and compliance infrastructures. An additional direction is extending the attestation mechanism to agentic workflows, where intermediate model outputs trigger external actions, enabling policy checks to be cryptographically enforced before such actions are executed.

REFERENCES

- [1] J. Groth, "On the size of pairing-based non-interactive arguments," in *Advances in Cryptology – EUROCRYPT 2016*, vol. 9666, 2016.
- [2] A. Gabizon, Z. J. Williamson, and O. Ciobotaru, "PLONK: Permutations over Lagrange-bases for oecumenical noninteractive arguments of knowledge," *Cryptology ePrint Archive*, Paper 2019/953, 2019.
- [3] E. Ben-Sasson, A. Chiesa, E. Tromer, and M. Virza, "Succinct non-interactive zero knowledge for a von Neumann architecture," in *Proc. 23rd USENIX Security Symp. (USENIX Security 14)*, pp. 781–796, 2014.
- [4] Electric Coin Company. Halo2: A PLONK-based zero-knowledge proving system. Available at: <https://github.com/zcash/halo2>
- [5] Zkonduit. EzKL: Zero-Knowledge Machine Learning Framework. Available at: <https://github.com/zkonduit/ezkl>
- [6] T. Liu, X. Xie, and Y. Zhang, "zkCNN: Zero knowledge proofs for convolutional neural network predictions and accuracy," *Cryptology ePrint Archive*, Paper 2021/673, 2021.
- [7] S. Lee, H. Ko, J. Kim, and H. Oh, "vCNN: Verifiable convolutional neural network based on zk-SNARKs," *IEEE Trans. Dependable Secure Comput.*, vol. 21, no. 4, pp. 4254–4270, 2024.
- [8] Y. Lindell and B. Pinkas, "Secure multiparty computation for privacy-preserving data mining," *JPC*, vol. 1, no. 1, 2009.
- [9] R. Gilad-Bachrach, N. Dowlin, K. Laine, K. Lauter, M. Naehrig, and J. Wernsing, "CryptoNets: Applying neural networks to encrypted data with high throughput and accuracy," in *Proc. 33rd Int. Conf. Mach. Learn. (ICML)*, pp. 201–210, 2016.
- [10] A. Brutzkus, R. Gilad-Bachrach, and O. Elisha, "Low latency privacy preserving inference," in *Proc. 36th Int. Conf. Mach. Learn. (ICML)*, pp. 812–821, 2019.
- [11] M. Mitchell *et al.*, "Model cards for model reporting," in *Proc. Conf. Fairness, Accountability, and Transparency (FAT*19)*, pp. 220–229, 2019.
- [12] T. Gebru, J. Morgenstern, B. Vecchione, J. W. Vaughan, H. Wallach, H. Daumé III, and K. Crawford, "Datasheets for datasets," 2021.
- [13] F. Dernoncourt, J. Y. Lee, O. Uzuner, and P. Szolovits, "De-identification of patient notes with recurrent neural networks," *J. Amer. Med. Inform. Assoc.*, vol. 24, no. 3, pp. 596–606, 2017.

Comparadores Eficientes en R1CS Mediante Acumulación Ponderada

Marc Guzmán-Albiol*, Marta Bellés-Muñoz†, Carla Brugulat-Rica*,
Rafael Genés-Durán*, Juan Jose Alins-Delgado* y Jose L. Muñoz-Tapia*

*Departamento de Ingeniería Telemática, Universidad Politécnica de Cataluña (UPC), 08034 Barcelona, España

†Departamento de Tecnologías de la Información y las Comunicaciones,

Universitat Pompeu Fabra (UPF), 08018 Barcelona, España

Correos electrónicos: {marc.guzman.albiol, rafael.genes, carla.brugulat, jose.luis.munoz}@upc.edu,
juanjo@entel.upc.edu, marta.belles@upf.edu

Resumen—Este artículo presenta un método optimizado para verificar la comparación de dos números binarios en el sistema de restricciones de rango uno (R1CS), un marco estándar en sistemas de computación verificable. Nos centramos en comparaciones estrictas del tipo $t > K$, donde K es una constante conocida y t el entero de entrada. Proponemos un método de *acumulación ponderada* que calcula un acumulador cuyo signo determina directamente el resultado de la comparación. Los bits se agrupan en pares y se asignan pesos según su posición, permitiendo actualizar el acumulador mediante restricciones de grado dos y evitando estructuras recursivas. Esta estrategia reduce significativamente el número total de restricciones y simplifica la lógica del circuito.

Index Terms—Computación Verificable, Optimización de Restricciones, R1CS, Comparadores Binarios

Tipo de contribución: Investigación ya publicada.

I. INTRODUCCIÓN

Los protocolos de *computación verificable* permiten que un *prover* convenza a un *verifier* de que un cálculo se ha realizado correctamente sin que este último tenga que reevaluarlo [1], [2], [3]. Este tipo de protocolos es relevante en escenarios donde tareas computacionalmente costosas se delegan a terceros, como la computación externalizada, en la nube o sistemas descentralizados.

Los sistemas modernos de computación verificable, y en particular los SNARKs, logran verificación eficiente apoyándose en criptografía de curvas elípticas con *pairings* bilineales [4], [5], [6]. En este contexto, los cálculos se expresan sobre un cuerpo primo $\mathbb{F}_p$, cuyos elementos se codifican como cadenas binarias de longitud fija, en nuestro caso de 254 bits. Es necesario garantizar que estos valores permanezcan dentro del rango válido $0, \dots, p-1$ para evitar codificaciones ambiguas o errores de *overflow* [7].

En la computación convencional, comprobar si un valor t satisface $t > K$ para una constante conocida K es trivial. Sin embargo, en SNARKs esta operación se traduce a un conjunto de ecuaciones algebraicas sobre $\mathbb{F}_p$ conocido como R1CS [8]. Las operaciones bit a bit y las condicionales deben descomponerse en ecuaciones de bajo nivel, aumentando significativamente el número de restricciones y afectando directamente el rendimiento [9].

Para abordar esto, proponemos un método de *acumulación ponderada* [10] que actualiza un acumulador basado en pares de bits y permite determinar la comparación final observando únicamente el signo del acumulador. Esta técnica mantiene

la suma dentro del rango del campo y reduce el número de restricciones significativamente. La implementación se realizó en *circom*, un DSL diseñado para R1CS [11].

II. METODOLOGÍA

El enfoque propuesto consiste en implementar un algoritmo de *acumulación ponderada* para la comparación de números binarios en R1CS. La idea central es asignar un peso a cada bit de los números de entrada, de manera que los bits de mayor orden tengan mayor influencia en el cálculo final, y luego combinar estos valores de forma lineal para determinar el resultado de la comparación.

A diferencia del método lexicográfico clásico, que compara los bits de mayor a menor de manera secuencial y genera una estructura recursiva que incrementa significativamente el número de restricciones, el enfoque propuesto pospone toda la comparación hasta el final. En lugar de evaluar cada bit de manera individual, primero se acumula el valor ponderado de todos los bits de entrada, y solo al final se determina el resultado de la comparación mediante la evaluación de un único bit de la suma ponderada. Esta estrategia evita la propagación recursiva de señales y reduce de manera sustancial el número de restricciones necesarias en el circuito.

Sin embargo, en lugar de procesar cada bit individualmente, el enfoque propuesto agrupa los bits en pares antes de realizar la suma ponderada. La razón principal de esta estrategia es que, si se acumulasen todos los pesos uno por uno, el número resultante podría ser demasiado grande para representarse dentro del circuito R1CS. Al acumular los pesos por pares de bits, se reduce el número de valores sumados a la mitad, manteniendo la suma acumulada dentro de límites manejables.

El procedimiento puede resumirse en los siguientes pasos:

1. **Asignación de pesos:** A cada par de bits se le asigna un peso que refleja su posición dentro del número binario.
2. **Acumulación ponderada:** El acumulador se actualiza progresivamente a partir de cada par de bits de t comparado con los bits correspondientes de la constante K . Dependiendo del resultado de la comparación del par, se suma, se resta o no se modifica el peso correspondiente en el acumulador. Cada par se procesa de forma independiente, por lo que no se genera ninguna estructura recursiva. Además, al ser los bits de K conocidos, cada actualización del acumulador puede representarse mediante una única restricción R1CS.

Tabla I
NÚMERO DE RESTRICCIONES Y MÉTRICAS DE RENDIMIENTO DE LOS DISEÑOS LEXICOGRAFICO Y PONDERADO, AGRUPADAS POR SISTEMA DE PRUEBA, TIPO DE MÉTRICA Y FASE.

Categoría	Métrica	Fase	Lexicográfico	Ponderado	Mejora
Configuración	Restricciones RICS	–	759	262	65.48 %
	Tiempo de cálculo del testigo	–	52 ms	35 ms	32.7 %
	Memoria máxima (RSS) del testigo	–	49 MB	46 MB	6.1 %
Groth16	Tiempo de ejecución	Generación de prueba	422 ms	375 ms	11.1 %
		Verificación	334 ms	320 ms	4.2 %
	Memoria máxima (RSS)	Generación de prueba	306 MB	278 MB	9.2 %
		Verificación	255 MB	254 MB	0.4 %
$\mathcal{P}lonK$	Tiempo de ejecución	Generación de prueba	1235 ms	837 ms	32.2 %
		Verificación	328 ms	318 ms	3.0 %
	Memoria máxima (RSS)	Generación de prueba	410 MB	343 MB	16.3 %
		Verificación	254 MB	253 MB	0.4 %
$fflonK$	Tiempo de ejecución	Generación de prueba	1557 ms	989 ms	36.5 %
		Verificación	335 ms	318 ms	5.1 %
	Memoria máxima (RSS)	Generación de prueba	787 MB	580 MB	26.3 %
		Verificación	254 MB	253 MB	0.4 %

3. **Evaluación del resultado:** A partir del valor acumulado final, se examina su signo, el cual determina directamente el resultado de la comparación entre t y K . De esta manera, toda la lógica de la comparación se traslada al final, eliminando la necesidad de comparaciones recursivas bit a bit.

III. RESULTADOS

Los resultados obtenidos muestran que el método de acumulación ponderada reduce significativamente el número de restricciones en comparación con el método lexicográfico. Como se observa en la Tabla I, mientras que la comparación lexicográfica requiere 759 restricciones no lineales para un valor de 254 bits, la variante por pares de la acumulación ponderada necesita solo 262, lo que representa una reducción del 65,5 %.

Esta disminución en el tamaño del circuito se refleja directamente en mejoras de rendimiento. La generación del witness y la construcción de pruebas se aceleran entre un 30 % y 37 %, con reducciones de memoria de hasta un 26 % en la fase de prueba más intensiva. La verificación también se beneficia, aunque de forma más modesta, con mejoras de entre 3 % y 5 %.

En conjunto, estos datos confirman que la optimización teórica en el conteo de restricciones se traduce en beneficios prácticos, haciendo que la acumulación ponderada sea más eficiente y adecuada para entornos de RICS que requieren múltiples comparaciones. La Tabla I resume estos resultados para los tres sistemas de pruebas evaluados (Groth16, $\mathcal{P}lonK$ y $fflonK$), mostrando claramente las ventajas de la implementación ponderada frente a la lexicográfica.

AGRADECIMIENTOS

Esta investigación fue financiada por el Instituto Nacional de Ciberseguridad (INCIBE) a través de la Cátedra Carismática INCIBE-UPC y por el proyecto español “Verifiable Computations and Applications” PID2024-159480OB-I00.

REFERENCIAS

- [1] L. Babai, L. Fortnow, L. A. Levin, and M. Szegedy, “Checking computations in polylogarithmic time,” in *Proceedings of the Twenty-Third Annual ACM Symposium on Theory of Computing*, ser. STOC ’91. New York, NY, USA: Association for Computing Machinery, 1991, p. 21–32. [Online]. Available: <https://doi.org/10.1145/103418.103428>
- [2] S. Micali, “CS proofs (extended abstracts),” in *35th Annual Symposium on Foundations of Computer Science, Santa Fe, New Mexico, USA, 20-22 November 1994*. IEEE Computer Society, 1994, pp. 436–453. [Online]. Available: <https://doi.org/10.1109/SFCS.1994.365746>
- [3] S. Goldwasser, Y. T. Kalai, and G. N. Rothblum, “Delegating computation: Interactive proofs for muggles,” *J. ACM*, vol. 62, no. 4, Sep. 2015. [Online]. Available: <https://doi.org/10.1145/2699436>
- [4] J. Groth, “On the size of pairing-based non-interactive arguments,” in *Advances in Cryptology - EUROCRYPT 2016 - 35th Annual International Conference on the Theory and Applications of Cryptographic Techniques, Vienna, Austria, May 8-12, 2016, Proceedings, Part II*, ser. Lecture Notes in Computer Science, M. Fischlin and J. Coron, Eds., vol. 9666. Springer, 2016, pp. 305–326.
- [5] A. Gabizon, Z. J. Williamson, and O. Ciobotaru, “PlonK: Permutations over Lagrange-bases for oecumenical noninteractive arguments of knowledge,” *Cryptology ePrint archive*, paper 2019/953, 2019. [Online]. Available: <https://eprint.iacr.org/2019/953>
- [6] D. F. Aranha, Y. E. Housni, and A. Guillevis, “A survey of elliptic curves for proof systems,” *Cryptology ePrint Archive*, Paper 2022/586, 2022.
- [7] V. I. 0xPARC Community, Ethereum Foundation, “Auditing report for circom-bigint,” October 2022, <https://veridise.com/wp-content/uploads/2023/02/VAR-circom-bigint.pdf>.
- [8] R. Gennaro, C. Gentry, B. Parno, and M. Raykova, “Quadratic span programs and succinct NIZKs without PCPs,” in *Advances in Cryptology - EUROCRYPT 2013*, T. Johansson and P. Q. Nguyen, Eds. Berlin, Heidelberg: Springer Berlin Heidelberg, 2013, pp. 626–645.
- [9] M. Bellés-Muñoz, J. Baylina, V. Daza, and J. L. Muñoz-Tapia, “New privacy practices for blockchain software,” *IEEE Software*, vol. 39, no. 3, pp. 43–49, 2022.
- [10] M. Guzmán-Albiol, M. Bellés-Muñoz, R. Genés-Durán, and J. L. Muñoz-Tapia, “Constraint-efficient comparators via weighted accumulation,” *Mathematics*, vol. 13, no. 24, p. 3959, 2025.
- [11] M. Bellés-Muñoz, M. Isabel, J. L. Muñoz-Tapia, A. Rubio, and J. Baylina, “Circom: A circuit description language for building zero-knowledge applications,” *IEEE Transactions on Dependable and Secure Computing*, vol. 20, no. 6, pp. 4733–4751, 2022.

Sesión de pósters 4

Sistema de esteganografía *coverless* en audio basado en generación musical

María-Iria Núñez-Vilabeirán

Universidad de Alcalá

Alcalá de Henares, Madrid, Spain

0009-0000-1735-089X

Carlos Cilleruelo-Rodríguez

Universidad de Alcalá

Alcalá de Henares, Madrid, Spain

0000-0001-7107-8655

Javier Junquera-Sánchez

Universidad de Alcalá

Alcalá de Henares, Madrid, Spain

0000-0002-4597-6539

José-Javier Martínez-Herráiz

Universidad de Alcalá

Alcalá de Henares, Madrid, Spain

0000-0002-2351-7163

Resumen—Este trabajo presenta un sistema de esteganografía *coverless* en audio basado en la generación determinista de contenido musical. El método propuesto genera directamente un archivo de audio con sentido musical a partir de reglas compositivas y mecanismos de control pseudoaleatorio, codificando el mensaje secreto como parte de la estructura durante el proceso de generación de la melodía sin necesitar ningún audio preexistente. Este enfoque elimina las trazas asociadas a la incrustación de información en audio y reduce significativamente la complejidad computacional del sistema.

Index Terms—esteganografía de audio *coverless*, MIDI, procesamiento digital de señales, audio digital.

Tipo de contribución: *Investigación en desarrollo*

I. INTRODUCCIÓN

LA esteganografía es considerada por muchos tanto una ciencia como un arte [1]. Basada tradicionalmente en ocultar mensajes o información secreta en medios comunes e inocuos como una imagen, un archivo de audio, un vídeo, etc., ha ido evolucionando hasta lo que se conoce hoy en día como estegosistema [2], llegando incluso a emplear redes generativas adversativas (GANs) [3].

La esteganografía en audio supone un gran reto debido a la alta sensibilidad del sistema auditivo humano. Además, la capacidad de ocultación en este medio resulta limitada y detectable mediante técnicas avanzadas de estegoanálisis.

Las técnicas clásicas de ocultación en audio, como la sustitución del bit menos significativo (LSB), se basan en modificar directamente muestras o coeficientes del medio portador. Aunque estos métodos resultan sencillos y fáciles de implementar, introducen alteraciones estadísticas que pueden ser detectadas [4]. Además, ofrecen menor capacidad esteganográfica y dejan trazas que modifican el audio original.

Es aquí donde la esteganografía *coverless* surge como una alternativa idónea para superar las limitaciones de los métodos tradicionales [5]. A diferencia de la esteganografía clásica, en la que se modifica un audio existente, los enfoques *coverless* evitan explícitamente cualquier alteración directa del medio, eliminando así las huellas estadísticas explotadas por los sistemas de estegoanálisis.

Este trabajo se enmarca en dicha línea de investigación, proponiendo una herramienta de esteganografía *coverless* en audio orientada a mejorar la seguridad frente a detectores basados en aprendizaje profundo, manteniendo al mismo tiempo una calidad perceptual adecuada. En este caso, el audio

transmitido se genera de manera que represente implícitamente la información secreta, lo que dificulta significativamente la detección de comunicación encubierta.

II. ESTADO DEL ARTE

La generación de contenido musical ha sido explorada como una alternativa a la modificación directa de señales de audio en sistemas esteganográficos [6], especialmente en contextos donde se busca reducir la detectabilidad de la comunicación encubierta.

Los primeros avances relevantes en esteganografía *coverless* en audio se apoyan en modelos generativos basados en GANs, destacando WaveGAN como uno de los primeros enfoques capaces de sintetizar formas de onda de audio directamente en el dominio temporal [7]. A partir de este modelo, diversos trabajos han propuesto sistemas de generación de estego-audios que evitan la modificación de un medio preexistente, mejorando la resistencia frente a estegoanálisis basado en redes neuronales.

Es importante destacar que el término *coverless* no implica la ausencia de un medio de transmisión, sino la inexistencia de un proceso de incrustación que altere un medio portador preexistente.

Investigaciones recientes [8] han explorado enfoques *coverless* alternativos basados en mapeo, prescindiendo del uso de redes neuronales generativas y centrándose en la extracción de características robustas combinada con estrategias de *clustering*. Se establecen reglas de mapeo entre el mensaje secreto y un conjunto de audios seleccionados a partir de procesos de *clustering*, sin modificar el portador. No obstante, estos métodos presentan limitaciones, como la necesidad de que emisor y receptor compartan conjuntos de datos idénticos.

En este contexto, el presente trabajo adopta una estrategia distinta, basada en la generación directa y determinista del portador musical, sin recurrir a bases de datos compartidas ni a procesos de *clustering*. Mientras que los enfoques *coverless* basados en mapeo codifican la información secreta mediante la selección de audios preexistentes, la propuesta aquí presentada genera contenido musical como medio de transmisión, eliminando la dependencia de un conjunto de datos y simplificando el proceso de sincronización entre emisor y receptor.

III. DISEÑO DEL SISTEMA

Se propone un sistema de esteganografía *coverless* basado en audio en el que el medio portador no se modifica, sino que se genera una pieza musical cuya estructura transporta el mensaje. El emisor transforma el texto en una secuencia de notas discretas y, mediante una contraseña compartida, dispersa esas notas dentro de la composición. El receptor, a partir del audio y la misma contraseña, detecta los eventos sonoros clave, extrae sus frecuencias dominantes y reconstruye el mensaje aplicando la misma lógica de dispersión inversa. En la Figura 1 se muestra el esquema del sistema propuesto.

III-A. Representación del mensaje a notación musical

El mensaje se procesa carácter a carácter. Cada carácter se convierte a un valor entero (representación numérica del carácter) y se descompone en tres bloques de tres bits, produciendo tres valores en el rango de cero a siete. Cada uno de estos valores se interpreta como un símbolo que se asigna a una frecuencia de un conjunto discreto de ocho notas predefinidas. Así, cada carácter queda representado por tres notas de mensaje, cada una perteneciente a ese conjunto finito.

III-B. Derivación de clave desde contraseña y dispersión

Para controlar la dispersión del mensaje se usa una clave precompartida, que debe ser conocida tanto por el emisor como por el receptor [9]. Lo que sitúa el sistema dentro del paradigma de esteganografía de clave simétrica, en el que ambas partes utilizan la misma clave secreta para la inserción y la extracción del mensaje. En este modelo, la seguridad no depende del ocultamiento del algoritmo, sino del secreto de la clave compartida, siguiendo el principio clásico de estegossistemas simétricos presentes en la literatura [2] [10].

En este sistema, a partir de la contraseña se deriva una clave numérica mediante el mecanismo de derivación de clave PBKDF2, obteniéndose así dos parámetros enteros, a y b , que definen una transformación afín módulo N . El primer parámetro se ajusta para ser invertible módulo N . Esta condición es necesaria para poder invertir la permutación en el receptor, como puede apreciarse en la Ecuación 1, donde i es el índice del mensaje, c_i la posición del compás resultante, a y b son parámetros enteros derivados de la clave (con a invertible módulo N), y N el número total de compases.

$$c_i = (ia + b) \bmod N \quad (1)$$

La dispersión se realiza asignando cada una de las notas del mensaje a una posición dentro del conjunto de compases mediante una transformación modular determinista dependiente de la clave, donde se fija el número total de compases como tres veces la longitud del texto en claro, garantizando que haya al menos una nota del mensaje por compás, es decir, una por cada bloque de tres bits.

Cada compás contiene varios *beats* o pulsos. Dentro de cada compás se inserta la nota del mensaje en un *beat* seleccionado de forma pseudoaleatoria determinista ya que es dependiente de la clave, mientras que el resto de *beats* se completan con notas de relleno extraídas de acordes que siguen una progresión armónica fija.

Las notas de relleno se eligen de los acordes asociados a la progresión; por tanto, sus frecuencias pertenecen al conjunto

de frecuencias de acordes, distinto del conjunto de ocho notas del mensaje (aunque parcialmente solapado). El criterio de ocultación no depende solo del valor frecuencial, sino de la posición temporal dentro del compás, que el receptor puede reproducir únicamente con la clave correcta.

III-C. Proceso de generación de audio

La composición resultante se exporta a un fichero MIDI (*Musical Instrument Digital Interface*), donde se asigna un instrumento y un tempo.

Posteriormente, el archivo MIDI se convierte a formato WAV (*Wave Audio Format*) mediante síntesis de audio y un banco de sonidos. Este proceso produce el archivo de audio final que se transmite como medio portador del mensaje.

III-D. Proceso de decodificación

Para el proceso de decodificación se prioriza la extracción de notas y frecuencias dominantes del audio. Para ello, el primer paso necesario es normalizar la señal. Para localizar las notas de forma precisa se emplea la detección de *onsets* (i.e. puntos exactos de inicio de un evento sonoro). Se toma una ventana temporal fija, ventana de Hann, para cada uno y se calcula su espectro mediante FFT para inferir qué frecuencias están más presentes en la señal junto con la intensidad de cada una. A continuación, se estiman las frecuencias dominantes que más se aproximan al conjunto discreto de frecuencias predefinidas, descartando aquellas que no encajan.

Finalmente, con los parámetros correctamente inferidos tras el análisis del audio, se deriva la misma clave a partir de la contraseña y se calcula el inverso modular necesario para revertir la dispersión. Se reordenan y agrupan nuevamente los eventos y para cada compás se selecciona el *beat* que corresponde a cada nota del mensaje.

IV. CONSIDERACIONES MUSICALES


La selección de la escala utilizada para las notas del mensaje no responde a una necesidad técnica de por sí, sino a una decisión de diseño conceptual y estético. En la implementación actual, las frecuencias asociadas a los bloques de información pertenecen a una escala pentatónica ampliada, mientras que las notas de relleno se extraen de acordes pertenecientes a su escala relativa.

Desde el punto de vista de diseño, el uso de una escala concreta no es una restricción del sistema, sino una instancia particular del modelo. El mecanismo de codificación únicamente requiere un conjunto discreto de ocho frecuencias para representar bloques de tres bits; por tanto, dicho conjunto puede redefinirse.

Del mismo modo, la progresión armónica empleada para las notas de relleno podría modificarse libremente. Por tanto, la dimensión musical del sistema no es meramente decorativa, sino un conjunto personalizable de parámetros que permite crear distintas melodías sin tener que manipular el mecanismo de codificación y decodificación.

V. RESULTADOS

El propósito de este apartado es exponer y analizar los resultados obtenidos con el sistema esteganográfico desarrollado. El objetivo principal es mostrar su funcionamiento, verificando que el sistema es capaz de codificar y recuperar

Figura 1. Diagrama del sistema de esteganografía *coverless* propuesto.

un mensaje oculto mediante la generación de un archivo de audio.

V-A. Casos de prueba

El proceso de codificación generó un archivo MIDI que fue posteriormente convertido a formato WAV. Este archivo contiene la secuencia musical completa, con las notas reales del mensaje ocultas entre notas de relleno que siguen una progresión tonal coherente. Durante las pruebas, se utilizaron diferentes tipos de mensajes y se configuraron distintas combinaciones de compás e instrumentos para analizar su impacto en la calidad del audio y la imperceptibilidad del mensaje.

En cada caso, el archivo MIDI fue generado y exportado correctamente como un archivo WAV, permitiendo que las notas de acompañamiento no interfirieran con la codificación del mensaje. A continuación, se genera un archivo de texto que contiene la clave y el número de compases, ambos necesarios para decodificar correctamente el mensaje.

En base a las pruebas realizadas, el sonido de piano fue el que mostró un mejor comportamiento en el proceso de decodificación del mensaje. Este resultado se debe a la mayor estabilidad espectral del instrumento, la definición clara de su ataque y la consistencia de su estructura armónica entre notas. En comparación, instrumentos como la guitarra acústica presentan vibraciones menos periódicas y una mayor variabilidad en sus armónicos, lo que puede introducir ambigüedades en la extracción de frecuencias y afectar de forma negativa a la decodificación del mensaje.

En el último caso de prueba, se codificó un mensaje breve utilizando el instrumento “piano eléctrico”. El archivo WAV generado por el sistema fue posteriormente comprimido a formato MP3 con el objetivo de evaluar la robustez frente a un formato de compresión con pérdidas. A pesar de la compresión aplicada, el proceso de decodificación mantuvo la integridad completa del mensaje.

Aunque la compresión introdujo una ligera degradación

en la fidelidad sonora. Este resultado indica que el sistema presenta resistencia frente a la compresión en formato MP3. No obstante, niveles de compresión más agresivos podrían generar distorsiones adicionales en determinadas bandas de frecuencia, lo que podría afectar al proceso de decodificación.

Los resultados más estables se obtuvieron empleando instrumentos de cuerda percutida, como piano clásico y piano eléctrico, cuya estructura espectral definida y ataque claramente delimitado favorecen la detección precisa de los eventos musicales. No obstante, la longitud del mensaje y la elección del instrumento son factores altamente relevantes en el proceso de decodificación.

En el caso de mensajes más extensos, se observó un incremento en la densidad y repetición de eventos musicales debido al mayor número de compases necesarios para codificar la información. Esta mayor extensión temporal puede hacer más evidente la estructura generada y, potencialmente, introducir acumulación de pequeñas imprecisiones en la extracción de notas.

VI. DISCUSIÓN

El sistema presentado ha confirmado la viabilidad de un sistema esteganográfico basado en la generación de melodías como medio para enviar y recibir información oculta. A diferencia de los métodos tradicionales basados en la modificación de archivos existentes, la propuesta desarrollada parte de la generación del audio desde cero. Este hecho, la sitúa dentro del enfoque de esteganografía sin portador, contribuyendo a una mayor resistencia frente a técnicas de detección por medio de estegonálisis.

Contrarrestar la estegonografía *coverless* es excesivamente complejo, debido a que los métodos actuales de estegonálisis intentan determinar si un medio dado ha sido modificado de forma esteganográfica. Sin embargo, dado que en los métodos *coverless* no se incrusta información en un portador preexistente, estos enfoques de detección resultan poco eficientes. Por

Tabla I
RESUMEN DE LOS CASOS DE PRUEBA

Caso	Instrumento	Compás	Formato	Longitud del mensaje	Resultado
Caso 1	Piano clásico	2/4	WAV	30 caracteres	Decodificación correcta
Caso 2	Guitarra acústica	4/4	WAV	10 caracteres	Errores en la extracción de frecuencias
Caso 3	Piano eléctrico	3/4	WAV	20 caracteres	Decodificación correcta
Caso 4	Piano eléctrico	3/4	MP3	20 caracteres	Decodificación correcta tras compresión con pérdidas

tanto, la esteganografía *coverless* presenta una clara ventaja frente a los métodos tradicionales tanto en imperceptibilidad para el oído humano como desde el punto de vista estadístico.

Por otra parte, los enfoques *coverless* basados en mapeo codifican la información secreta mediante la selección y ordenación de muestras de audio preexistentes, donde cada elemento transmitido permanece acústicamente intacto y no presenta modificaciones respecto a su versión original. Este procedimiento puede entenderse como análogo al uso extensivo de *sampling* en producción musical, en el que el significado no reside en la alteración del material sonoro, sino en su elección y disposición.

En estos sistemas, la naturalidad del resultado final no proviene de la coherencia global del audio transmitido, sino de la plausibilidad individual de cada muestra seleccionada.

Estudios que emplean esta estrategia [8] reconocen de forma implícita estas limitaciones, al señalar la necesidad de grandes conjuntos de datos previamente procesados y sincronizados entre emisor y receptor. Asimismo, el envío reiterado de fragmentos de corta duración puede constituir un patrón observable que, en determinados escenarios, podría suscitar sospechas ante un estegoanalista.

En contraste, los enfoques *coverless* basados en generación algorítmica producen el portador como una única entidad coherente, integrando el mensaje secreto durante el proceso de creación del contenido. Esta estrategia elimina la necesidad de seleccionar fragmentos de un conjunto de datos compartido y reduce la dependencia del contexto externo para garantizar la naturalidad del audio transmitido. En particular, la generación musical determinista permite mantener una estructura sonora consistente, evitando posibles discontinuidades perceptivas asociadas a la concatenación o selección de audios heterogéneos.

Los enfoques basados en generación ofrecen mayor flexibilidad y simplicidad operativa, al prescindir de bases de datos compartidas y procesos de clasificación o búsqueda. Estas características hacen que la generación directa de contenido resulte especialmente adecuada para escenarios donde la coherencia perceptual y la independencia del entorno de transmisión constituyen requisitos clave.

VII. CONCLUSIÓN

Se ha presentado una propuesta preliminar de un sistema de esteganografía *coverless* en audio basado en la generación determinista de contenido musical. El software resultante implementa nuestra propuesta de técnica esteganográfica que produce piezas musicales a partir de parámetros algorítmicos. Al sintetizar la información secreta directamente en la sintaxis musical, se eliminan las trazas propias de la esteganografía de sustitución o modificación. En consecuencia, el sistema reduce la carga computacional y mejora la resistencia ante el análisis forense de audio. En trabajos futuros, se estudiará la

capacidad de parametrizar características del audio a generar y dotarlo de mayor realismo.

AGRADECIMIENTOS

Los autores agradecen a la Cátedra de Investigación IS-DEFE-Universidad de Alcalá y a sus colaboradores por el apoyo y los recursos proporcionados para el desarrollo de este trabajo.

REFERENCIAS

- [1] Kefa Rabah. "Steganography-The Art of Hiding Data". En: *Information Technology Journal* 3 (mar. de 2004). DOI: 10.3923/itj.2004.245.269.
- [2] C. Cachin. "An information-theoretic model for steganography". En: vol. 192. Jul. de 2004, págs. 306-318. ISBN: 9783540653868. DOI: 10.1007/3-540-49380-8_21.
- [3] Jing Li, Kaixi Wang y Xiaozhu Jia. "A Coverless Audio Steganography Based on Generative Adversarial Networks". En: *Electronics* 12.5 (2023). ISSN: 2079-9292.
- [4] Trivikram Muralidharan et al. "The infinite race between steganography and steganalysis in images". En: *Signal Processing* 201 (2022), pág. 108711. ISSN: 0165-1684. DOI: <https://doi.org/10.1016/j.sigpro.2022.108711>.
- [5] Kamred Udham Singh. "A Survey on Audio Steganography Approaches". En: *International Journal of Computer Applications* 95.14 (jun. de 2014), págs. 7-14. ISSN: 0975-8887. DOI: 10.5120/16660-6640. URL: <https://ijcaonline.org/archives/volume95/number14/16660-6640/>.
- [6] L. Meng, X. Jiang y T. Sun. "A Review of Coverless Steganography". En: *Neurocomputing* 566 (2024), pág. 126945.
- [7] Chris Donahue, Julian McAuley y Miller Puckette. *Adversarial Audio Synthesis*. 2019. arXiv: 1802.04208. URL: <https://arxiv.org/abs/1802.04208>.
- [8] Yan Feng et al. "A Robust Coverless Audio Steganography Based on Differential Privacy Clustering". En: *IEEE Transactions on Multimedia* 27 (2025), págs. 5669-5684. DOI: 10.1109/TMM.2025.3543107.
- [9] Luis von Ahn y Nicholas J. Hopper. "Public-Key Steganography". Inglés. En: *Proceedings of EUROCRYPT 2004*. Interlaken, Switzerland: Springer, 2004. URL: <https://www.cs.cmu.edu/~biglou/pubkeystego.pdf>.
- [10] Yahia Sabri Al-Halabi. "A Symmetric Key Based Steganography Calculation for Anchored Information". En: *Journal of Theoretical and Applied Information Technology* 98.1 (2020). URL: <https://www.jatit.org/volumes/Vol98No1/10Vol98No1.pdf>.

Detección automática de audio generado por Inteligencia Artificial

Victoria García Martínez-Echevarría
Universidad Pontificia Comillas
Escuela de Ingeniería ICAI
victoria.garcia@alu.comillas.edu

Rafael Palacios Hielscher
Massachusetts Institute of Technology
Cybersecurity at MIT Sloan
rafael.palacios@iit.comillas.edu

Gregorio López López
Universidad Pontificia Comillas
Instituto de Investigación Tecnológica
gllopez@icai.comillas.edu

Resumen—La accesibilidad y el creciente realismo de los sistemas modernos de síntesis y conversión de voz han intensificado la necesidad de mecanismos fiables para detectar audios generados por Inteligencia Artificial en contextos con requisitos críticos de seguridad. Este artículo analiza la detección automática de voz sintética en un entorno de duración controlada (2-4 segundos) mediante el reentrenamiento de dos sistemas de referencia del conjunto *Logical Access* del *ASVspoof 2019 Challenge*. El primero es una red convolucional residual entrenada como clasificador binario, mientras que el segundo adopta una estrategia de aprendizaje de una sola clase con arquitectura ResNet-18. Además, se comparan los resultados de un estudio de identificación realizado con usuarios a través de una plataforma web. Los resultados experimentales muestran que el enfoque de una sola clase generaliza mejor frente a ataques no vistos; en cambio, los humanos cometen más errores, especialmente ante voces sintéticas modernas de alta calidad.

Index Terms—*One-class learning*, detección de *spoofing*, *deep-fakes*, redes neuronales convolucionales (CNNs), síntesis de audio

I. INTRODUCCIÓN

Durante la última década, los avances en Inteligencia Artificial (IA) han dado lugar a sistemas que permiten crear contenido sintético cada vez más realista de múltiples tipos, (texto, imágenes, vídeo y audio). En particular, los sistemas actuales de síntesis de habla y conversión de voz pueden generar voces que reproducen con gran fidelidad las características y los matices de la voz humana [1]. Sin embargo, esto ha provocado que aumente la preocupación sobre la autenticidad y la confianza en las interacciones mediadas por la voz. Desde el punto de vista de la seguridad, las voces sintéticas pueden usarse para suplantar la identidad y atacar servicios basados en la identificación por voz, como la autenticación biométrica y los asistentes personales inteligentes.

Ya se han reportado casos reales que evidencian el potencial de los *deepfakes* de voz para eludir medidas de seguridad y comprometer la confianza en las transacciones digitales, e incluso los delincuentes pueden usar *deepfakes* parciales para estafar tanto a personas como a sistemas automatizados. Estas amenazas han motivado líneas de investigación específicas sobre audio sintético y medidas de detección, así como estándares de evaluación (como los retos ASVspoof) [2], [3] y datasets públicos.

En la literatura, los primeros sistemas de detección se basaban en modelos estadísticos como GMM (*Gaussian Mixture Models*) con características acústicas clásicas, incluyendo MFCC (Mel-Frequency Cepstral Coefficients), LFCC (Log-Frequency Cepstral Coefficients), CQCC (Constant Q Cepstral Coefficients), etc. [4].

Con la adopción del aprendizaje profundo, arquitecturas como CNN-RNN (*Convolutional Recurrent Neural Networks*) o ResNet (*Residual Networks*) con función de pérdida *One-Class Softmax* [5] mejoraron notablemente los resultados, siendo esta última capaz de detectar ataques no vistos durante el entrenamiento con un EER (Equal Error Rate) del 2,19 % en el conjunto LA del *ASVspoof 2019 Challenge*. Trabajos posteriores incorporaron mecanismos de atención y variantes avanzadas como Res2Net [6], consolidando la tendencia hacia arquitecturas profundas especializadas. A pesar de los avances, la detección robusta de voces sintéticas sigue siendo un desafío, especialmente cuando los modelos se enfrentan a métodos de síntesis no conocidos durante el entrenamiento.

II. METODOLOGÍA

Para estudiar la detección automática de audio generado por IA, adaptamos y reentrenamos modelos de referencia del ASVspoof 2019 Challenge (partición *Logical Access*, LA), filtrando el conjunto de datos para incluir únicamente muestras de entre dos y cuatro segundos, con el fin de evitar sesgos asociados a la duración. Además, diseñamos un experimento complementario para evaluar la percepción humana en la misma tarea [7].

II-A. Características del Audio

Se consideran cuatro representaciones acústicas como entrada a los modelos. Los espectrogramas corresponden a la magnitud logarítmica de la STFT (*Short-Time Fourier Transform*), calculada con ventanas de Hamming de tamaño 2048 y solapamiento del 25 %; conservan información espectral detallada y permiten que las redes aprendan patrones discriminativos a partir de una entrada poco procesada [8]. Los MFCC se obtienen proyectando el espectro sobre un banco de filtros en escala Mel y aplicando una DCT, utilizándose los primeros 24 coeficientes por cuadro; ofrecen una representación compacta aunque pueden perder sensibilidad ante distorsiones sutiles [8]. Los CQCC se basan en la CQT, que emplea intervalos de frecuencia espaciados geoméricamente, ofreciendo mayor resolución en bajas frecuencias; han demostrado superar a los coeficientes cepstrales tradicionales al resaltar artefactos en todo el espectro. Los LFCC siguen un procedimiento similar al de los MFCC pero con un banco de filtros en escala lineal, preservando mejor los detalles de alta frecuencia donde suelen aparecer anomalías del audio sintético [9].

II-B. Diseño de los Modelos

El primer modelo, basado en la propuesta de Alzantot et al. (2019) [8], emplea una arquitectura ResNet profunda con bloques residuales que incluyen capas convolucionales, normalizaciones, activaciones *leaky-ReLU* y *dropout*, seguidos de capas totalmente conectadas que producen una predicción binaria. Se entrenan tres variantes independientes con espectrogramas, MFCC y CQCC como entrada, y el entrenamiento minimiza una pérdida de entropía cruzada estándar.

El segundo modelo, propuesto por Zhang et al. (2020) [5], adopta un enfoque de aprendizaje de una sola clase (*one-class Learning*) mediante una arquitectura ResNet-18 sobre características LFCC. En lugar de una clasificación binaria, modela únicamente la distribución del habla real mediante la función de pérdida OC-Softmax, que proyecta los embeddings sobre una hipersfera unitaria y penaliza desviaciones respecto al centro compacto de la clase auténtica; durante la inferencia, las muestras alejadas de dicha región se consideran potencialmente falsificadas.

II-C. Recopilación de Datos de Usuarios

Para complementar la evaluación automática, se utilizó un servidor interactivo [7] en el que los participantes clasificaban clips de voz como *Humano*, *Suena humano*, *Suena a IA* o *IA*. El servidor incluía 701 muestras del conjunto de evaluación filtrado de ASVspoof 2019 (LA) y ocho muestras externas generadas con herramientas comerciales (PlayHT [10], Resemble AI [11] y LOVO [12]), todas restringidas a audios de entre dos y cuatro segundos.

El experimento se estructuró en sesiones de 10 clips, completándose 108 sesiones y obteniéndose 1.080 decisiones en total. Para la comparación con los modelos, las cuatro opciones se fusionaron en dos categorías binarias: Humano (Humano + Suena humano) e IA (Suena a IA + IA).

III. IMPLEMENTACIÓN Y EXPERIMENTOS

Los experimentos consisten en reentrenar modelos de detección de *spoofing* en el subconjunto filtrado de ASVspoof 2019 y evaluarlos tanto en las particiones de desarrollo y evaluación como en un conjunto externo de muestras generadas por herramientas de terceros, comparando su rendimiento con el de oyentes humanos.

III-A. Conjunto de Datos

Se utilizó la partición LA (*Logical Access*) de ASVspoof 2019, organizada en tres particiones (entrenamiento, desarrollo y evaluación) con distribución equilibrada de hablantes [13]. Como se menciona en la sección anterior, se filtraron las muestras para conservar únicamente audios de entre dos y cuatro segundos; y, aunque este filtrado reduce el número total de muestras, el equilibrio entre clases se mantiene similar al del conjunto original (véase Tabla I).

Adicionalmente, se incorporó un pequeño conjunto externo de ocho muestras (seis generadas con PlayHT [10], ResembleAI [11] y LOVO [12], y dos reales) para evaluar la generalización frente a técnicas modernas no vistas [7].

Set	Class	Original Count	Original %	Filtered Count	Filtered %
train	SP	22800	89.83 %	13208	87.63 %
	BF	2580	10.17 %	1865	12.37 %
dev	SP	22296	89.74 %	12350	88.2 %
	BF	2548	10.26 %	1653	11.8 %
eval	SP	63882	89.68 %	33401	86.17 %
	BF	7355	10.32 %	5360	13.83 %

Tabla I: Conteos y proporciones (SP-BF) antes y después de filtrar los datos por duración.

III-B. Entrenamiento y Validación

El proceso de entrenamiento siguió estrictamente las configuraciones recomendadas en los trabajos originales [5], [8], preservando arquitecturas, optimizadores y demás hiperparámetros para garantizar que las diferencias de rendimiento se debieran al conjunto de datos filtrado. La principal variable experimental fue el número de épocas: para cada tipo de representación de entrada se entrenaron múltiples versiones del modelo variando la duración del entrenamiento, aplicando en algunos casos detención temprana cuando no se observaban mejoras adicionales en la función de pérdida.

El rendimiento se evaluó mediante la precisión (accuracy) y el Equal Error Rate (EER), métrica estándar en detección de spoofing que identifica el punto en que la tasa de aceptación falsa (FAR) y la tasa de rechazo falso (FRR) coinciden.

III-C. Análisis del Rendimiento

El rendimiento de los modelos se analiza desde tres perspectivas: (i) entrenamiento y desarrollo, (ii) conjunto de evaluación y (iii) conjunto externo. En los dos últimos casos, los modelos se enfrentan a datos no vistos y generados con técnicas distintas a las del entrenamiento, lo que permite evaluar su capacidad de generalización.

Para realizar una comparación clara entre representaciones de audio, se seleccionó una única versión representativa por tipo de característica, priorizando buen rendimiento con menor número de épocas y tomando como criterio la precisión en evaluación. Las configuraciones elegidas fueron: 100 épocas para el modelo basado en espectrogramas, 75 épocas para MFCC, 100 épocas para CQCC y 75 épocas para LFCC.

En los conjuntos de entrenamiento y desarrollo, todos los modelos alcanzan precisiones muy altas (Tabla II). La precisión en entrenamiento es prácticamente perfecta en todos los casos, mientras que en desarrollo apenas disminuye, salvo en los modelos basados en MFCC, donde se observa mayor sensibilidad al sobreajuste. Los valores de EER en desarrollo son superiores a los reportados en los trabajos originales, lo que no resulta sorprendente dado que el filtrado reduce el tamaño del dataset y restringe la variabilidad temporal.

Model	Train accuracy	Dev accuracy	Dev EER	Original Dev EER
spect_100	1.000000	0.995358	0.004263	0.0011
mfcc_75	0.999668	0.972577	0.043822	0.0334
cqcc_100	0.999934	0.995001	0.006728	0.0001
lfcc_75	1.000000	0.997143	0.007395	0.0020

Tabla II: Precisión y valores EER de cada modelo en los conjuntos de entrenamiento y desarrollo.

El comportamiento cambia notablemente en el conjunto de evaluación (Tabla III), donde todas las arquitecturas experimentan una caída de precisión, especialmente el modelo basado en espectrogramas. En contraste, el modelo basado en LFCC obtiene los mejores resultados, con una precisión del 93,46 % y los valores de EER más bajos ($\approx 0,035$), lo que confirma la mayor capacidad de generalización del enfoque de aprendizaje de una sola clase frente a ataques no vistos.

Model	Eval Accuracy	EER	Original Eval EER
spect_100	0.797348	0.125166	0.0968
mfcc_75	0.842393	0.147221	0.0933
cqcc_100	0.833338	0.104786	0.0769
lfcc_75	0.934573	0.036393	0.0219

Tabla III: Precisión y valores EER de cada modelo en el conjunto de evaluación.

En el conjunto externo, el rendimiento global disminuye respecto al conjunto de evaluación (Figura 1), especialmente en el modelo CQCC. El modelo LFCC vuelven a obtener los mejores resultados, con un 87,5 % de precisión, aunque el tamaño reducido del conjunto limita la robustez estadística de estas conclusiones.




Figura 1: Precisión de cada modelo en el conjunto externo.

IV. RESULTADOS

Dado que este trabajo analiza dos fuentes de rendimiento distintas, los resultados de modelos automáticos y usuarios se presentan por separado.

IV-A. Modelos Automáticos

Como se describió en la sección anterior, se seleccionó una configuración representativa por tipo de característica (espectrogramas a 100 épocas, MFCC a 75, CQCC a 100 y LFCC a 75). Los resultados detallados por partición se recogen en las tablas II y III: todos los modelos alcanzaron precisión casi perfecta en entrenamiento y desarrollo, pero el rendimiento cae ante técnicas no vistas, siendo LFCC el más robusto (93,46 % en evaluación y 87,5 % en el conjunto externo) y CQCC el que peor generaliza.

Para analizar qué técnicas resultaron más difíciles, se calculó la precisión media por método (Figura 2). Las técnicas A17 y A18 destacan como las más problemáticas, con precisiones medias del 19,7 % y 51,0 %, respectivamente. Ambas se basan en sistemas avanzados de conversión de voz no paralelos [13]: A17 emplea una arquitectura VAE con modificación directa de forma de onda [14], y A18 un marco de *i-vectors* y PLDA con aprendizaje por transferencia [15].




Figura 2: Precisión media por método de *spoofing* en el conjunto de evaluación.

En el conjunto externo *Clara* (Tabla IV), todos los modelos clasificaron correctamente las muestras de PlayHT y LOVO, mientras que ResembleAI resultó la técnica más engañosa: solo los modelos MFCC y LFCC acertaron la mitad de sus muestras, y CQCC no clasificó correctamente ninguna. Estas diferencias pueden explicarse por las distintas arquitecturas internas de cada herramienta, que generan artefactos acústicos diferentes y afectan de manera desigual a cada modelo.

Model	PlayHT	ResembleAI	LOVO
spect_100	1.0	1.0	1.0
mfcc_75	1.0	0.5	1.0
cqcc_100	1.0	0.0	1.0
lfcc_75	1.0	0.5	1.0
Accuracy	1.0	0.5	1.0

Tabla IV: Precisión de cada modelo en el conjunto de datos *Clara* por técnica de *spoofing*.

En definitiva, los resultados automáticos muestran que el enfoque de una sola clase basado en LFCC ofrece la mejor generalización, aunque ningún modelo es completamente robusto frente a todos los métodos no vistos.

IV-B. Usuarios

En el experimento con el servidor web [7] participaron 80 personas en 108 sesiones, generando 1.080 respuestas: 972 sobre ASVspoof y 108 sobre el conjunto externo. La Tabla V resume la precisión global y por subconjunto.

Set	Global Acc.	AI Acc.	Human Acc.	AI Prop.	Human Prop.
Entire dataset	0.6685	0.6239	0.7487	63.75 %	36.25 %
ASVspoof 2019	0.6986	0.6780	0.7339	63.62 %	36.38 %
Clara (external)	0.3981	0.2025	0.9310	75.00 %	25.00 %

Tabla V: Precisión global y por clase, junto con la proporción de muestras de IA y humanas en cada conjunto.

IV-B1. Rendimiento global

La precisión global fue del 66,85 %, con una tasa de error del 33,15 %. Los participantes identificaron mejor el audio humano (74,9 %) que el sintético (62,4 %), y mostraron una asimetría clara: tendieron más a aceptar como humano un audio falso (37,6 %) que a rechazar erróneamente uno auténtico (25,1 %).

IV-B2. Análisis por subconjunto

Al separar los datos por conjunto, se observa que el rendimiento humano varía significativamente. En ASVspoof,

la precisión global fue del 69,86 %, con tasas relativamente equilibradas (67,8 % en sintéticos y 73,4 % en auténticos). En el conjunto externo, el rendimiento cayó drásticamente hasta el 39,81 %: aunque la identificación de muestras humanas fue alta (93,1 %), el 79,7 % de las muestras falsificadas se clasificaron erróneamente como humanas, lo que indica que los oyentes aceptan con facilidad voces sintéticas modernas de alta calidad. Cabe resaltar que, dado el tamaño reducido de este conjunto, las conclusiones deben interpretarse con cautela, aunque la tendencia es consistente y significativa.

IV-B3. Dificultad por método

Las técnicas más engañosas para los participantes fueron las tres herramientas del conjunto externo (PlayHT, ResembleAI y LOVO, con precisiones del 6,7 %, 27,3 % y 29,3 % respectivamente) y la técnica A10 de ASVspoof (26,6 %), basada en Tacotron 2 con vocoder WaveRNN [16], lo que confirma que los sistemas TTS neuronales modernos superan fácilmente la percepción humana (Figura 3).




Figura 3: Precisión media por técnica de *spoofing* para los humanos.

IV-C. Comparación entre modelos y humanos

Comparando ambas fuentes de resultados, los modelos automáticos superan sistemáticamente a los humanos: el mejor modelo (LFCC) alcanza más del 93 % en evaluación, frente al 70 % humano en ese subconjunto, y ambos caen en el conjunto externo, aunque los humanos lo hacen de forma más pronunciada (por debajo del 40 %).

Modelos y humanos fallan por razones distintas: los humanos son especialmente susceptibles al realismo perceptual de voces modernas, mientras que los modelos sufren ante técnicas no vistas o altamente adaptativas. A pesar de estas limitaciones, los detectores automáticos ofrecen una ventaja clara y consistente, lo que refuerza la necesidad de desarrollar sistemas robustos frente a la evolución continua de la síntesis de voz.

V. CONCLUSIÓN

En este trabajo se reentrenaron y analizaron distintos modelos de detección de voz sintética sobre un subconjunto filtrado del dataset ASVspoof 2019 (restringido a audios de entre dos y cuatro segundos), evaluándolos tanto en sus particiones estándar como en un conjunto externo, y comparando su rendimiento con el de usuarios humanos en la misma tarea.

El modelo basado en LFCC con *one-class learning* ofrece la mejor capacidad de generalización frente a técnicas no vistas, mientras que los modelos basados en espectrogramas,

MFCC y CQCC, pese a alcanzar rendimientos casi perfectos en entrenamiento y desarrollo, presentan caídas significativas en escenarios más exigentes. Por su parte, los usuarios mostraron una dificultad considerable para identificar voces sintéticas modernas, con una tendencia marcada a clasificarlas como humanas. Cabe destacar que las técnicas más problemáticas para los modelos no siempre coincidieron con las que engañaron a los humanos, evidenciando diferencias en los criterios de detección. En conjunto, los modelos superaron consistentemente a los humanos, lo cual subraya la importancia de desarrollar sistemas automáticos robustos para contrarrestar las amenazas emergentes de los *deepfakes* de voz.

Como líneas de trabajo futuro, se plantea ampliar el rango de duraciones, incorporar grabaciones en distintos entornos y ampliar el conjunto externo con más herramientas comerciales de síntesis.

REFERENCIAS

- [1] H. Barakat, O. Turk, and C. Demiroglu, "Deep Learning-based Expressive Speech Synthesis: A Systematic Review of Approaches, Challenges, and Resources," Dec. 2024.
- [2] Z. Wu, T. Kinnunen, N. Evans, J. Yamagishi, C. Hanilci, M. Sahidullah, and A. Sizov, "ASVspoof 2015: the First Automatic Speaker Verification Spoofing and Countermeasures Challenge," Tech. Rep. [Online]. Available: <http://www.festvox.org/>
- [3] A. Nautsch, X. Wang, N. Evans, T. Kinnunen, V. Vestman, M. Todisco, H. Delgado, M. Sahidullah, J. Yamagishi, and K. A. Lee, "ASVspoof 2019: Spoofing Countermeasures for the Detection of Synthesized, Converted and Replayed Speech," Feb. 2021. [Online]. Available: <http://arxiv.org/abs/2102.05889>
- [4] M. Neelima and I. S. Prabha, "Hybrid Feature Optimization for Voice Spoof Detection Using CNN-LSTM," *Traitement du Signal*, vol. 41, pp. 717–727, Apr. 2024.
- [5] Y. Zhang, F. Jiang, and Z. Duan, "One-class Learning Towards Synthetic Voice Spoofing Detection," Oct. 2020. [Online]. Available: <http://arxiv.org/abs/2010.13995>
- [6] Q. Shen, M. Guo, Y. Huang, and J. Ma, "Attentional Multi-Feature Fusion for Spoofing-Aware Speaker Verification," *International Journal of Speech Technology*, vol. 27, 06 2024.
- [7] C. Palacios-Castrillo, R. Palacios, R. Gesteira-Miñarro, A. Chávez-Macías, and G. López, "Analysis of the Security and Privacy of Smart Personal Assistants with Real and Synthetic Voices," *Journal of Information Security and Applications* (), vol. Under Review, 2025.
- [8] M. Alzantot, Z. Wang, and M. B. Srivastava, "Deep Residual Neural Networks for Audio Spoofing Detection," in *Proceedings of the Annual Conference of the International Speech Communication Association, INTERSPEECH*, vol. 2019-September. International Speech Communication Association, 2019, pp. 1078–1082.
- [9] M. Todisco, H. Delgado, and N. Evans, "Constant Q Cepstral Coefficients: A Spoofing Countermeasure for Automatic Speaker Verification," Tech. Rep., 2017.
- [10] PlayHT, "PlayHT: AI Voice Generator and Text-to-Speech Platform," accessed: 2025-05-06. [Online]. Available: <https://play.ht/>
- [11] ResembleAI, "Resemble AI: AI Voice Generator and Deepfake Detection for Enterprise," accessed: 2025-05-06. [Online]. Available: <https://www.resemble.ai/>
- [12] LovoAI, "LOVO AI: AI Voice Generator and Text-to-Speech Platform," accessed: 2025-05-06. [Online]. Available: <https://lovo.ai/>
- [13] X. W. et al., "ASVspoof 2019: A Large-scale Public Database of Synthesized, Converted and Replayed Speech," Nov. 2019. [Online]. Available: <http://arxiv.org/abs/1911.01601>
- [14] W.-C. H. et al., "Generalization of Spectrum Differential based Direct Waveform Modification for Voice Conversion," Jul. 2019. [Online]. Available: <http://arxiv.org/abs/1907.11898>
- [15] T. Kinnunen, L. Juvela, P. Alku, and J. Yamagishi, "Non-parallel voice conversion using i-vector plda: Towards unifying speaker verification and transformation," in *ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings*. Institute of Electrical and Electronics Engineers Inc., Jun. 2017, pp. 5535–5539.
- [16] J. S. et al., "Natural TTS Synthesis by Conditioning Wavenet on MEL Spectrogram Predictions," in *2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2018, pp. 4779–4783.

Métodos de detección e investigación forense de amenazas de *insiders* en contextos corporativos: Un meta-estudio

David Melendi
Universidad de Oviedo
melendi@uniovi.es

Xabiel G. Pañeda
Universidad de Oviedo
xabiel@uniovi.es

Víctor Corcoba
Universidad de Oviedo
corcobavictor@uniovi.es

Roberto García
Universidad de Oviedo
garciaroberto@uniovi.es

Resumen- Los *insiders* son usuarios de una organización con determinados privilegios que, consciente o inconscientemente, producen un incidente de ciberseguridad. Dado que actúan desde el interior de la organización y que tienen acceso a sus activos, las actividades de prevención son más complejas que las que tradicionalmente se venían empleando. Los incidentes de *insiders* tienen un alto impacto en las organizaciones en las que se producen y provocan pérdidas económicas cuantiosas. Dado que es un campo de investigación en el que se lleva trabajando algunos años, en este estudio se presenta un análisis de un número relevante de investigaciones anteriores. Se resumen algunos de los resultados alcanzados en la detección e investigación de incidentes de *insiders* en entornos corporativos. Adicionalmente y dado que la mayoría de los trabajos analizados destaca problemas relacionados con los datos para el entrenamiento de modelos, hemos realizado un estudio sobre la disponibilidad de conjuntos de datos o *datasets* en la literatura científica

Index Terms- detección de *insiders*, investigación de *insiders*, *datasets* de *insiders* para el entrenamiento de modelos

Tipo de contribución: Investigación original

I. INTRODUCCIÓN

Las amenazas de *insiders* son acciones maliciosas realizadas por usuarios con acceso legítimo a los sistemas de una organización. Estas acciones, que pueden haber sido intencionadas o involuntarias, suponen un gran riesgo para todo tipo de organizaciones. Comúnmente, se materializan en exfiltraciones de datos, pérdidas económicas y graves daños reputacionales. Dentro de las amenazas de *insiders* destacan las relacionadas con el crimen en el puesto de trabajo, que se puede definir como una acción maliciosa cometida por una persona o grupo de personas en el transcurso de una ocupación legítima. El impacto de este tipo de incidentes es enorme, tal y como queda acreditado por la Asociación de Auditores de Fraude Certificados (ACFE). En su último informe [1], analizan 1.921 casos en 138 países ocurridos entre enero de 2022 y julio de 2024. Las pérdidas fueron aproximadamente de 3.100 millones de dólares. En dicho informe se realiza una estimación global de pérdidas de beneficios del 5% por este tipo de fraudes.

Debido al alto impacto que tienen estos incidentes, su detección temprana e investigación posterior son aspectos de especial relevancia. No obstante, los métodos de detección tradicionales son poco efectivos en la actualidad. Además de no proporcionar garantías forenses, estos métodos se pueden burlar y deben ser actualizados constantemente. Nuevas estrategias de ataque potenciadas por inteligencia artificial

complican aún más esta situación. Por ello, es necesario investigar sobre métodos de detección que vayan más allá de los controles de seguridad tradicionales y que puedan afrontar las amenazas actuales. Adicionalmente, es importante que los procesos de detección permitan realizar la atribución de los incidentes con garantías desde un punto de vista judicial, incorporando capacidades forenses. Debido a estas limitaciones, se han publicado diversos trabajos en la materia en los últimos años, principalmente enfocados en el desarrollo de nuevos métodos de detección. Estos métodos incluyen la utilización de técnicas de inteligencia artificial o el análisis del comportamiento de los usuarios, entre otros. No obstante, también se han publicado algunos trabajos sobre sistemas “Forensic-Ready”, que van más allá de las tareas de detección. Todos estos desarrollos han permitido mejorar las capacidades de las organizaciones facilitando, al mismo tiempo, las investigaciones post-incidente. No obstante, estos métodos también deben afrontar diferentes retos. Los más problemáticos están relacionados con los datos disponibles para las tareas de entrenamiento de modelos: escasez de datos reales, desequilibrios entre acciones normales y fraudulentas en los datos o aspectos relacionados con la privacidad de los usuarios. Adicionalmente, cabe destacar la dificultad en la detección de desviaciones de comportamiento de los usuarios que en algunos casos pueden ser imperceptibles y la necesidad de disponer de sistemas de detección en tiempo real que sean transparentes desde el punto de vista de la investigación.

En este trabajo se analizan trabajos anteriores sobre la detección e investigación de incidentes de *insiders*. Se realiza un breve resumen de algunos de los resultados alcanzados en dichos estudios. Adicionalmente, se ha completado el estudio con un análisis acerca de la disponibilidad de *datasets* que potencialmente puedan ser utilizados para la realización de pruebas o para el entrenamiento de modelos.

El resto de este trabajo se ha estructurado como sigue. En la Sección II se comentan algunos aspectos metodológicos. En la Sección III se describen los principales resultados de la búsqueda realizada. En la Sección IV se realiza una discusión de los resultados encontrados. Finalmente, la Sección V presenta las conclusiones del trabajo y expone algunas potenciales líneas de investigación futuras.

II. METODOLOGÍA

Para llevar a cabo este estudio, se realizaron búsquedas de trabajos relacionados con la detección e investigación de *insiders*. Se realizaron en las plataformas *Web of Science*, *Google Scholar* y *Scopus* utilizando los siguientes criterios:

- Trabajos acerca de detección e investigación de amenazas de *insiders* (“insider threat detection and investigation”), publicados entre 2015 y 2025.
- Trabajos sobre *datasets* relacionados con la investigación de *insiders* (“insider dataset”/“insiders dataset”), publicados entre los años 2015 y 2025.

Bajo los criterios comentados, para la primera búsqueda se obtuvieron los siguientes resultados:

- En la plataforma *Web of Science* se encontraron 56 trabajos cuya temática o “topic” se ajustaba al criterio de búsqueda. La naturaleza de los trabajos es diversa, habiendo sido clasificados en un total de 25 categorías.
- En cuanto a *Scopus*, se encontraron un total de 2.889 trabajos tras realizar la búsqueda sobre cualquiera de los campos accesibles en la herramienta. Los resultados muestran trabajos clasificados en diversas categorías, siendo la predominante la informática (31,8%). También se aprecia un interés creciente sobre la temática, a la vista del número de trabajos publicados los últimos 10 años. También que, aunque la mayoría de los trabajos son artículos en revista (44,3%), se han publicado numerosas revisiones bibliográficas sobre la materia (278 en total).
- En *Google Scholar* se encontraron 17.400 trabajos aproximadamente.

Por otro lado, utilizando los criterios comentados sobre la segunda búsqueda se obtuvieron los siguientes resultados:

- En *Web of Science* se encontraron 2 trabajos cuya temática o “topic” se ajustaba al criterio de búsqueda.
- En cuanto a *Scopus*, se encontraron un total de 5 trabajos. Todos categorizados en informática, aunque con otras categorías secundarias.
- En la plataforma *Google Scholar* se encontraron un total de 62 trabajos.

De los trabajos encontrados en la primera búsqueda, se han analizado los 50 que se han considerado más relevantes. En cuanto a la segunda búsqueda, se han analizado los 10 trabajos que han recibido un mayor número de citas.

III. RESULTADOS

A. Detección e investigación de insiders

En los trabajos que han sido revisados se han identificado diferentes técnicas entre las que destacan las siguientes:

1. Aproximaciones basadas en el aprendizaje automático, utilizando métodos supervisados o no supervisados. Ejemplos son soluciones basadas en redes neuronales, aprendizaje profundo o métodos de *clustering*. Son los más abundantes y consiguen tasas de detección muy satisfactorias. No obstante, muchos de los sistemas supervisados se entrenan con *datasets* existentes y no con datos obtenidos por los investigadores. Adicionalmente, muchos de estos *datasets* son sintéticos. Es muy destacable el uso del *CERT Insider Threat dataset* [12]. Se proponen principalmente soluciones basadas en el análisis de logs, llamadas al sistema, tráfico de red y del comportamiento de los usuarios [3] - [5], [11], [13] - [25].

2. Métodos forenses de análisis de logs, tráfico de red y artefactos de memoria. El análisis de logs se utiliza para detectar anomalías en el comportamiento de los usuarios [6],

[10], [11], [13], [16], [23] - [24], [25]. También se analiza el tráfico de red para identificar actividades sospechosas [15], [26] y se utilizan artefactos de memoria y disco como mecanismos de evidenciar la actividad de los usuarios, incluso en entornos con cifrado [17], [20].

3. Trabajos que investigan en el desarrollo de modelos híbridos y de inteligencia artificial explicativa (XAI). Los primeros combinan distintas técnicas para mejorar la detección de amenazas [2], [4], [6] - [7], [14], [19], [21], [27] - [28]. Los segundos están siendo estudiados en la actualidad para servir de soporte en investigaciones forenses [7], [29], proporcionando información transparente sobre la detección.

4. Métodos de trazabilidad basados en cadenas de bloques, para garantizar la integridad de las evidencias. Esto es especialmente crítico en casos de *insiders* que tienen acceso privilegiado a los sistemas que generan y custodian los registros que pueden ser utilizados para la detección y atribución de los incidentes. Se han publicado diferentes trabajos que proponen la utilización de cadenas de bloques para garantizar la inmutabilidad de estos datos [30] - [32].

5. Sistemas “Forensic-Ready” que utilizan métodos forenses de recolección de evidencias [8], [10], [26], [30], [31], [32]. De esta forma, se obtienen garantías de que las evidencias digitales se han generado correctamente y que pueden ser utilizadas en las investigaciones.

B. *Datasets* relacionados con casos de insiders

En cuanto a la disponibilidad de *datasets* sobre casos de *insiders*, se pueden destacar los siguientes trabajos:

1. Al-Shehari, T. y Alsowail [18] utilizan el *CERT Insider Threat dataset* [12]. Es sintético y contiene registros generados a partir de la actividad de unos hipotéticos trabajadores. Incluye datos sobre el uso de HTTP, correo electrónico, etc. Los autores preprocesan el *dataset* y utilizan la técnica SMOTE para solucionar desequilibrios en los datos.

2. AlSlaiman et al. [21] también utilizan el *CERT Insider Threat dataset* [12]. Clasifican los datos utilizando análisis de sentimiento y codificación Gray. También se mencionan otros *datasets*: Sentiment140 [33] con datos sobre una red social; KDD CUP1999 y NSL-KDD [34] con muestras de tráfico; y correos publicados tras una investigación a Enron [35].

3. Lavanya et al. [22] utilizan el *CERT Insider Threat dataset* [12]. Proponen una alternativa para solventar desequilibrios que combinan con una red neuronal profunda.

4. Al-Mhiqani et al. [36] revisan trabajos anteriores sobre *insiders* y reflejan un uso mayoritario del *CERT Insider Threat dataset* [12], aunque mencionan otros: NSL-KDD [34] que ya se ha descrito; Remote Terminal Unit (RTU) [37] con conexiones en un sistema industrial; Schonlau [38] con comandos ejecutados por usuarios; APEX’07 [39] con actividades de usuarios de servicios de inteligencia; RUU [40] con trazas recogidas de Windows; y TWOS [41], con datos recogidos en un evento junto con información de personalidad.

5. Park et al. [42] analizan redes sociales para detectar potenciales amenazas. Utilizan el *dataset* Sentiment140 [33]. También mencionan el *CERT Insider Threat dataset* [12], Schonlau [38] y el TWOS [41].

6. Ahmed Khan et al. [43] presentan un marco de trabajo para la detección de *insiders* basado en UEBA. Los autores utilizan el *CERT Insider Threat dataset* [12].

7. Li et al. [44] proponen un método de detección de *insiders* que se basa en visión por computador. Los autores utilizan exclusivamente el *CERT Insider Threat dataset* [12].

8. Kim et al. [45] presentan un sistema basado en cadenas de Markov y solo usan el *CERT Insider Threat dataset* [12].

9. Amuda et al. [46] presentan un sistema híbrido de detección que se basa en redes neuronales convolucionales y redes neuronales recurrentes GRU. Este estudio se basa solamente en el *CERT Insider Threat dataset* [12].

10. Orizio et al. [47] proponen un modelo de aprendizaje auto explicativo basado en restricciones. También se basa en el *CERT Insider Threat dataset* [12].

IV. DISCUSIÓN

De los trabajos analizados, se pueden destacar las siguientes cuestiones relevantes:

- Los modelos de aprendizaje automático han permitido mejorar la detección de amenazas de *insiders*. Dado que algunos de estos modelos presentan limitaciones, existen investigaciones que proponen técnicas combinadas en un modelo híbrido, obteniendo tasas de detección elevadas y cierta adaptabilidad en entornos cambiantes.
- El uso de inteligencia artificial explicativa incrementa la confiabilidad y la transparencia de los sistemas.
- La mayoría de los trabajos se basan en el análisis y utilización de registros de log y/o de tráfico de red. Estas contextualizadas pueden ser utilizadas tanto en tareas de detección como de atribución. Son la principal fuente de datos tanto para el entrenamiento de modelos como para las tareas ordinarias de detección.
- Aunque la mayoría de los trabajos se centran en el análisis de la actividad de los usuarios, existen algunos que tienen en cuenta aspectos emocionales y psicosociales.
- La tecnología de cadenas de bloques puede utilizarse para garantizar la integridad de los datos que se recopilan por los sistemas de detección e investigación.
- Los sistemas “Forensic-Ready” facilitan las tareas de investigación post-incidente.
- Aunque existen *datasets* que contienen información recuperada de entornos reales, es predominante el uso del *CERT Insider Threat dataset* [12].

No obstante, todavía existen algunos retos en este campo:

- La detección de *insiders* necesita de una cantidad ingente de datos. Su escasez, la existencia de “ruido” o artefactos indeseados o la ausencia de una documentación adecuada son grandes problemas que es necesario tener en cuenta. La mayoría de los trabajos soluciona este problema utilizando *datasets* sintéticos. Por otro lado, el desequilibrio de casos en los datos de entrenamiento de los sistemas supervisados es también muy problemático.
- Otro reto está relacionado con la selección de fuentes de datos y características para el entrenamiento de modelos y las tareas de detección. En un entorno real se genera un alto volumen de datos heterogéneos y esto puede generar problemas de escalabilidad.
- La diferenciación precisa entre comportamientos normales y anómalos de los usuarios es otro aspecto problemático. Los sistemas de detección basados en el aprendizaje de patrones de normalidad, pueden generar errores debido a la sutilidad en los comportamientos y a

cambios de comportamiento legítimos de los usuarios.

- La adaptabilidad a nuevas amenazas es otro reto. Cuando surgen nuevas estrategias de ataque o los atacantes alteran su comportamiento, los modelos de aprendizaje automático pueden no llegar a ser efectivos. La técnica de aprendizaje concreta utilizada puede ser determinante en la adaptabilidad de estos sistemas a nuevas amenazas.
- También están aspectos relacionados con la privacidad de los usuarios. Los sistemas de detección necesitan acceder a los sistemas de los usuarios finales y a sus comunicaciones, lo que implica, en muchos casos, acceder a datos que pueden pertenecer a la órbita personal. Por ello, la elaboración de políticas de seguridad transparentes, el desarrollo de modelos auto-explicables y la utilización de técnicas no intrusivas son aspectos fundamentales para garantizar la confianza de los usuarios.

V. CONCLUSIONES

Los métodos para detectar e investigar incidentes de *insiders* en entornos corporativos han avanzado significativamente en los últimos años. Principalmente, gracias a la incorporación de técnicas de inteligencia artificial y al diseño de sistemas novedosos como pueden ser las soluciones “Forensic-Ready”. Existe un interés creciente sobre la temática en la comunidad investigadora, a la vista de la evolución en el número de trabajos publicados. Entre estos trabajos, se ha observado la presencia de numerosos estudios sobre el estado de la cuestión.

Existen todavía algunos retos como pueden ser aquellos relacionados con la escasez de datos, cuestiones relacionadas con la privacidad de los usuarios y la natural evolución de las amenazas. Las investigaciones futuras en este campo deben centrarse en solucionar los retos mencionados e intentar dar respuesta a las siguientes cuestiones:

- ¿Cómo se pueden integrar diferentes tecnologías para disponer de soluciones de detección que puedan adaptarse a un escenario de amenazas cambiante?
- ¿Cuáles son las fuentes de datos y características que deben ser monitorizadas en un entorno corporativo, dependiendo de sus características específicas, para no producir problemas de escalabilidad en los sistemas de detección?
- ¿Cómo se pueden integrar métodos que garanticen la privacidad de los usuarios en los procesos de detección de incidentes de *insiders*?
- ¿De qué forma se pueden desplegar sistemas “Forensic-Ready” en entornos corporativos heterogéneos de forma que se garantice la recogida y custodia de evidencias digitales?
- ¿Cómo se pueden evolucionar los sistemas de inteligencia artificial auto-explicables para poder ser utilizados en investigaciones forenses? Mejorar la transparencia de estos sistemas es importante desde el punto de vista jurídico y procedimental.

AGRADECIMIENTOS

Este trabajo ha sido financiado por el Ministerio de Ciencia, Innovación y Universidades, la Agencia Estatal de Investigación y el Fondo Europeo de Desarrollo Regional (MICIU / AEI / 10.13039 / 501100011033 / FEDER, UE) a través del Proyecto PID2024-155581OB-C22.

REFERENCIAS

- [1] Association of Certified Fraud Examiners (ACFE): "Occupational Fraud 2024: A Report To The Nations", 2024.
- [2] Kim, J., Park, M., Kim, H., Cho, S. y Kang, P.: "Insider Threat Detection Based on User Behavior Modeling and Anomaly Detection Algorithms", en *Applied Sciences*, vol. 9(19), n. 4018, 2019.
- [3] Yuan, S. y Wu, X.: "Deep Learning for Insider Threat Detection: Review, Challenges and Opportunities", en *Comp. & Sec.*, vol. 104, 2021.
- [4] Pal, P., Chattopadhyay, P. y Swarnkar, M.: "Temporal feature aggregation with attention for insider threat detection from activity logs", en *Expert Systems with Applications*, vol. 224, n. 119925, 2023.
- [5] Alzaabi, F. R. y Mehmood, A.: "A Review of Recent Advances, Challenges, and Opportunities in Malicious Insider Threat Detection Using Machine Learning Methods", en *IEEE Access*, vol. 12, 2024.
- [6] Wang, Z. Q., Wang, H. y El Saddik, A.: "FedITD: A Federated Parameter-Efficient Tuning With Pre-Trained Large Language Models and Transfer Learning Framework for Insider Threat Detection", en *IEEE Access*, vol. 12, pp. 160396-160417, 2024.
- [7] Alketbi, K. y Mehmood, A.: "A Comprehensive Survey of Explainable Artificial Intelligence Techniques for Malicious Insider Threat Detection", en *IEEE Access*, vol. 13, pp. 121772-121798, 2025.
- [8] Leu, F., Tsai, K., Hsiao, Y. y Yang, C.: "An Internal Intrusion Detection and Protection System by Using Data Mining and Forensic Techniques", en *IEEE Systems Journal*, vol. 11(2), pp. 427-438, 2017.
- [9] Alsowail, R. y Al-Shehari, T.: "Empirical Detection Techniques of Insider Threat Incidents", en *IEEE Access*, vol. 8, 2020.
- [10] Daubner, L., Macak, M., Matulevicius, R., Buhnova, B., Maksovic, S. y Pitner, T.: "Addressing insider attacks via forensic-ready risk management", *Journal of Inf. Sec. and Apps.*, vol. 73, n. 103433, 2023.
- [11] Fei, K., Zhou, J., Zhou, Y., Gu, X., Fan, H., Li, B., Wang, W. y Chen, Y.: "LaAeb: A comprehensive log-text analysis based approach for insider threat detection", en *Comp. & Sec.*, vol. 148, n. 104126, 2025.
- [12] Computer Emergency Response Team (CERT): "The CERT Insider Threat Database", Software Engineering Institute, Universidad Carnegie Mellon, 2016 [Online]. Último acceso el 28 de enero de 2026. Disponible en <https://www.sei.cmu.edu/library/insider-threat-test-dataset/>.
- [13] Tuor, A., Kaplan, S., Hutchinson, B., Nichols, N. y Robinson, S.: "Deep learning for unsupervised insider threat detection in structured cybersecurity data streams," en actas del *AAAI-17 Workshop on Artificial Intelligence for Cyber Security*, pp. 224-231, 2017.
- [14] Gamachchi, A., Sun, L. y Boztas, S.: "Graph based framework for malicious insider threat detection", *50th Hawaii Int. Conference on System Sciences (HICSS-50)*, Hawaii, USA, pp. 2638-2647, 2017.
- [15] Soh, C., Yu, S., Narayanan, A., Duraisamy, S. y Chen, L.: "Employee profiling via aspect-based sentiment and network for insider threats detection", en *Expert Systems with Applications*, vol. 135, 2019.
- [16] Liu, L., Chen, C., Zhang, J., De Vel, O. y Xiang, Y.: "Insider Threat Identification Using the Simultaneous Neural Learning of Multi-Source Logs", en *IEEE Access*, vol. 7, pp. 183162-183176, 2019.
- [17] Nasir, R., Afzal, M., Latif, R. y Iqbal, W.: "Behavioral Based Insider Threat Detection Using Deep Learning", en *IEEE Access*, vol. 9, 2021.
- [18] Al-Shehari, T. y Alsowail, R.: "An Insider Data Leakage Detection Using One-Hot Encoding, Synthetic Minority Oversampling and Machine Learning Techniques", en *Entropy*, vol. 23(10), n. 11362, 2021.
- [19] Al-Mhiqani, M., Ahmad, R., Abidin, Z., Abdulkareem, K., Mohammed, M., Gupta, D. y Shankar, K.: "A new intelligent multilayer framework for insider threat detection", en *Comp. and Elec. Eng.*, vol. 97, 2022.
- [20] Villarreal-Vasquez, M., Modelo-Howard, G., Dube, S. y Bhargava, B.: "Hunting for Insider Threats Using LSTM-Based Anomaly Detection", en *IEEE Trans. on Dependable and Sec. Comp.*, vol. 20(1), 2023.
- [21] Alslaiman, M., Salman, M., Saleh, M. y Wang, B.: "Enhancing false negative and positive rates for efficient insider threat detection", en *Computers & Security*, vol. 126, n. 103066, 2023.
- [22] Lavanya, P., Glory, H. y Shankar Sriram, V.: "Mitigating Insider Threat: A Neural Network Approach for Enhanced Security", en *IEEE Access*, vol. 12, pp. 73752-73768, 2024.
- [23] Cai, X., Wang, Y., Xu, S., Li, H., Zhang, Y., Liu, Z. y Yuan, X.: "LAN: Learning Adaptive Neighbors for Real-Time Insider Threat Detection", en *IEEE Trans. on Inf. Forensics and Security*, vol. 19, 2024.
- [24] Mladenovic, D., Antonijevic, M., Jovanovic, L., Simic, V., Zivkovic, M., Bacanin, N., Zivkovic, T. y Perisic, J.: "Sentiment classification for insider threat identification using metaheuristic optimized machine learning classifiers", en *Scientific Reports*, vol. 14, n. 25731, 2024.
- [25] Lavanya, P., Glory, H., Aggarwal, M. y Shankar Sriram, V.: "Unmasking insider threats using a robust hybrid optimized generative pretrained neural network approach", en *Scientific Reports*, vol. 15, n. 26718, 2025.
- [26] Punithavathani, D. S., Sujatha, K., Jain, J. M.: "Surveillance of anomaly and misuse in critical networks to counter insider threats using computational intelligence", *Cluster Comp.*, vol. 18, pp. 435-451, 2015.
- [27] Singh, M., Mehtre, B. M., Sangeetha, S. y Govindaraju, V.: "User Behaviour based Insider Threat Detection using a Hybrid Learning Approach", en *Journal of Ambient Intel. and Humanized Computing*, vol. 14, pp. 4573-4593, 2023.
- [28] Xiao, H., Zhu, Y., Zhang, B., Lu, Z., Du, D. y Liu, Y.: "Unveiling shadows: A comprehensive framework for insider threat detection based on statistical and sequential analysis", *Comp. & Security*, vol. 138, 2024.
- [29] Amiri-Zarandi, M., Karimipour, H. y Dara, R. A.: "A federated and explainable approach for insider threat detection in IoT", en *Internet of Things*, vol. 24, 2023.
- [30] Li, S., Qin, T. y Min, G.: "Blockchain-Based Digital Forensics Investigation Framework in the Internet of Things and Social Systems", *IEEE Trans. on Comp. Social Systems*, vol. 6(6), pp. 1433-1441, 2019.
- [31] Hu, T., Xin, B., Liu, X., Chen, T., Ding, K. y Zhang, X.: "Tracking the Insider Attacker: A Blockchain Traceability System for Insider Threats", en *Sensors*, vol. 20(18), 2020.
- [32] Zarpala, L. y Casino, F.: "A blockchain-based forensic model for financial crime investigation: the embezzlement scenario", en *Digital Finance*, vol. 3, pp. 301-332, 2021.
- [33] Go, A., Bhayani, R. y Huang, L.: "Twitter sentiment classification using distant supervision", informe de proyecto CS224N, Stanford 1(12) 2009.
- [34] Tavallae, M., Bagheri, E., Lu, W. y Ghorbani A.: "A detailed analysis of the KDD CUP 99 data set", en actas del *2009 IEEE Symposium on Computational Intelligence for Security and Defense Applications*, Ottawa, Canada, 2009.
- [35] Shetty, J. y Adibi, J.: "The Enron email dataset database schema and brief statistical report", University of Southern California, vol. 4(1), 2004.
- [36] Al-Mhiqani, M. N., Ahmad, R., Abidin Z. Z., Yassin W., Hassan, A., Abdulkareem, K. H., Ali, N.S., Yunus, Z.: "A Review of Insider Threat Detection: Classification, Machine Learning Techniques, Datasets, Open Challenges, and Recommendations", *Applied Sciences*, vol. 10, 2020.
- [37] Beaver, J. M., Borges-Hink, R. C., Buckner, M. A.: "An Evaluation of Machine Learning Methods to Detect Malicious SCADA Communications", en actas del *2013 12th International Conference on Machine Learning and Applications (ICMLA)*, vol. 2, pp.54-59, 2013.
- [38] Schonlau, M.: "Masquerading User Data". [Online]. Último acceso el 10 de enero de 2026. Disponible en: <https://www.schonlau.net>.
- [39] Santos, E., Nguyen, H., Yu, F., Kim, K. J., Li, D., Wilkinson, J. T., Olson, A., Russell, J., Clark, B.: "Intelligence Analyses and the Insider Threat" *IEEE Trans. on Systems, Man, and Cyber.*, vol. 42, pp. 331-347, 2012.
- [40] Song, Y., Salem, M. B., Hershkop, S., Stolfo, S. J.: "System level user behavior biometrics using Fisher features and Gaussian mixture models", en *2013 IEEE Security and Privacy Workshop*, San Francisco, 2013.
- [41] Harilal, A., Toffalini, F., Castellanos, J., Guarizo, J., Homoliak, I. y Ochoa, M.: "TWOS: A dataset of malicious insider threat behavior based on a gamified competition", *2017 International Workshop on Managing Insider Security Threats*, ACM, New York, USA, pp. 45-56, 2017.
- [42] Park, W., You, Y. y Lee, K.: "Detecting Potential Insider Threat: Analyzing Insiders' Sentiment Exposed in Social Media", en *Security and Communication Networks*, vol. 2018, n. 7243296, 2018.
- [43] Ahmed Khan, M. Z., Mubashir Khan, M. y Arshad, J.: "Anomaly Detection and Enterprise Security using User and Entity Behavior Analytics (UEBA)", *3rd Int. Conf. on Innovations in Computer Science & Software Engineering (ICONICS)*, Karachi, Pakistan, pp. 1-9, 2022.
- [44] Li, D., Yang, L., Zhang, H., Wang, X., Ma, L., Xiao, J.: "Image-Based Insider Threat Detection via Geometric Transformation", en *Security and Communication Networks*, vol. 2021, n. 1777536, 2021.
- [45] Kim, D. W., Hong, S. S. y Han, M. M.: "A study on Classification of Insider threat using Markov Chain Model", en *KSII Transactions on Internet and Information Systems*, vol. 12(4), pp. 1887-1898, 2018.
- [46] Amuda, O. K., Akinyemi, B. O., Sanni, M. L. y Aderounmu, G. A.: "A Predictive User Behaviour Analytic Model for Insider Threats in Cyberspace", en *International Journal of Communication Networks and Information Security (IJCNIS)*, vol. 14(1), pp. 150-159, 2022.
- [47] Orizio, R., Vuppala, S., Basagiannis S. y Provan, G.: "Towards an Explainable Approach for Insider Threat Detection: Constraint Network Learning", en actas del *2020 Int. Conf. on Intelligent Data Science Technologies and Applications (IDSTA)*, Valencia, pp. 42-49, 2020.

De Insultos a Identificadores: Enmascaramiento con LLMs y Aumento de Datos Iterativo para la Detección de Discurso de Odio Multiclase

Marcos Rodríguez Vega

Universidad de La Laguna

Dpto. de Ingeniería Informática y de Sistemas
mrodrive@ull.edu.es

Pino Caballero-Gil

Universidad de La Laguna

Dpto. de Ingeniería Informática y de Sistemas
pcaballe@ull.edu.es

Resumen—Presentamos una arquitectura híbrida para la detección multiclase de discurso de odio, diseñada para operar bajo estrictas restricciones de coste y latencia. Los grandes modelos de lenguaje (LLM) se emplean exclusivamente en la fase *offline* para enmascarar insultos y menciones a colectivos atacados, sustituyéndolos por identificadores normalizados (ej. [SLUR:], [TARGET:]). Además, introducimos Telephone-Game Augmentation (TGA), una técnica iterativa de aumento de datos que genera paráfrasis conservando la semántica para equilibrar las clases minoritarias. Durante el despliegue (*online*), clasificadores ligeros procesan estas entradas garantizando una latencia mínima y predecible. Las evaluaciones demuestran que el enmascaramiento incrementa el F1-macro promedio en +0.073 para clasificación binaria. En escenarios multiclase con escasez de datos (≈ 20 muestras por clase), TGA supera a la retrotraducción. Estos resultados consolidan una solución robusta para la moderación que protege la privacidad y mitiga la evolución léxica del discurso ofensivo sin sacrificar la eficiencia.

Index Terms—Moderación Online, Detección de discursos de odio, Data augmentation, LLM masking, Low-resource models

Tipo de contribución: Investigación original

I. INTRODUCCIÓN

Las Redes Sociales y Medios en Línea se han convertido en infraestructuras críticas para el discurso público, situando a la moderación de contenidos como un desafío sociotécnico de primer orden (1). Las plataformas deben operar bajo estrictos presupuestos de latencia y coste mientras hacen frente a comportamientos adversarios a gran escala. Aunque los grandes modelos de lenguaje (LLM) han supuesto un avance en la comprensión de la toxicidad, su coste computacional dificulta su despliegue en *pipelines* de producción que exigen decisiones rápidas (2). Esto motiva la adopción de arquitecturas híbridas: utilizar los LLM *offline* durante la preparación de datos y el entrenamiento, manteniendo la inferencia en tiempo real rápida mediante clasificadores ligeros (3).

Un obstáculo persistente en la detección multiclase de discurso de odio es la combinación del desequilibrio de clases y la evolución léxica o *concept drift*. Los insultos cambian rápidamente, y los modelos tradicionales tienden a sobreajustarse a estos términos superficiales en lugar de capturar la estructura semántica (4). Simultáneamente, la revisión manual de conjuntos de datos es lenta y costosa.

Nuestro enfoque aborda este problema separando el léxico volátil del proceso lógico. Aplicamos un enmascaramiento asistido por LLM, sustituyendo los insultos explíci-

tos por identificadores normalizados. Además, proponemos Telephone-Game Augmentation (TGA), un esquema iterativo de paráfrasis respaldado por LLM para mitigar la escasez de datos en clases minoritarias.

Nuestras principales contribuciones son: (1) Un *pipeline* de enmascaramiento para sustituir términos volátiles; (2) TGA, una técnica iterativa de aumento de datos; (3) Una evaluación exhaustiva bajo restricciones de eficiencia.

II. TRABAJOS RELACIONADOS

La moderación automática de contenidos ha evolucionado significativamente en los últimos años. Tradicionalmente, se dependía de listas de bloqueo léxicas y modelos de bolsa de palabras, enfoques frágiles ante la ofuscación de texto y cambios en la jerga de los usuarios (5). Con la llegada de arquitecturas basadas en Transformers, la capacidad para detectar lenguaje abusivo implícito mejoró drásticamente, pero introdujo cuellos de botella severos en la latencia de inferencia, limitando su viabilidad para flujos de datos a escala global (6).

Para abordar la escasez de datos etiquetados en categorías minoritarias, la literatura ha explorado técnicas de aumento de datos. Métodos clásicos como la inserción o reemplazo aleatorio de sinónimos (7) a menudo destruyen la coherencia gramatical del mensaje original. La retrotraducción (*back-translation*) ofrece paráfrasis más naturales, pero tiende a suavizar la toxicidad del texto o perder la direccionalidad del odio hacia el colectivo específico (8). Recientemente, el uso de modelos generativos para la síntesis de datos ha mostrado resultados prometedores (9), aunque el desafío de mantener la diversidad léxica sin incurrir en bucles repetitivos sigue siendo un área de investigación activa, vacío que nuestra propuesta de TGA con memoria (RAG) busca llenar.

III. METODOLOGÍA

Nuestra arquitectura delega la carga generativa a un proceso en segundo plano (*offline*), permitiendo que un modelo robusto instruya a los clasificadores ligeros para el despliegue (*online*).

III-A. Enmascaramiento de Objetivos e Insultos

El objetivo es sustituir formas superficiales volátiles por marcadores normalizados. De este modo, los clasificadores ligeros pueden centrarse en señales composicionales. Las referencias a colectivos se mapean a marcadores como

[TARGET:<CÓDIGO>] y [SLUR:<CÓDIGO>]. Todas las sustituciones están restringidas por una taxonomía cerrada (ej. ETH_BLACK, GENDER_WOMEN).




Figura 1. Ilustración del pipeline para el enmascaramiento asistido.

El proceso de extracción y anonimización se formaliza en el Algoritmo 1. Como ilustra la Figura 1, el modelo identifica cualquier grupo protegido atacado, reemplaza las menciones por marcadores y devuelve el texto enmascarado. Reglas deterministas posteriores reemplazan nombres de usuario y URLs.

Algorithm 1 Masking and Lexicon Extraction

Require: Corpus D split in train/val/test, closed taxonomy $\mathcal{T}$, generative model M

- 1: **for** each post $x_i \in D$ **do**
- 2: Query model M with x_i and taxonomy $\mathcal{T}$
- 3: Receive masked text m_i with slot markers
- 4: Apply deterministic rules: replace users, URLs, tags
- 5: Store $(x_i, m_i, \text{targets}, \text{metadata})$
- 6: **end for**
- 7: **for** each pair (x_i, m_i) **do**
- 8: Align original and masked fragments to locate surface forms
- 9: Extract candidate expressions associated with taxonomy codes
- 10: Normalize forms (lowercase, lemmatization, noise removal)
- 11: **end for**
- 12: **return** Masked corpus and lexicon statistics

III-B. Aumento de Datos Iterativo (Telephone-Game)

Para abordar el desequilibrio de clases, TGA amplía la cobertura lingüística de los textos de entrenamiento enmascarados preservando la semántica. Partiendo de una instancia enmascarada x_0 , TGA produce una cadena:

$$x_{t+1} = f_\theta(x_t, \mathcal{M}_t), \quad t = 0, \dots, k-1, \quad (1)$$

donde f_θ es un modelo generativo restringido para preservar la etiqueta, copiar los marcadores textualmente y fomentar la diversidad.

Exploramos dos variantes detalladas en el Algoritmo 2: **TGA Simple**, donde cada paso se condiciona solo a la salida anterior, y **TGA con Memoria (RAG)**, que recupera vecinos cercanos y los proporciona como ejemplos negativos para disuadir al modelo de usar fraseología repetitiva.

Algorithm 2 Telephone-Game Augmentation (TGA)

Require: Masked corpus D , taxonomy $\mathcal{T}$, augmentation budget K

- 1: **for** each class $c \in \mathcal{T}$ **do**
- 2: Calculate needed samples n_c to balance class c
- 3: **for** each sample $x_0 \in D_c$ **do**
- 4: $x_{seed} \leftarrow x_0$
- 5: $P_0 \leftarrow \text{extract\_markers}(x_0)$
- 6: **for** $t = 1$ to k **do**
- 7: **if** Simple Variant **then**
- 8: $x_{cand} \leftarrow f_\theta(x_{seed})$
- 9: **else**
- 10: $\mathcal{M}_t \leftarrow \text{get\_nearest\_neighbors}(x_{seed}, \mathcal{M}_c)$
- 11: $x_{cand} \leftarrow f_\theta(x_{seed}, \mathcal{M}_t)$
- 12: **end if**
- 13: **if** $\text{markers}(x_{cand}) = P_0$ **and** $\text{sim}(x_{cand}, x_0) \geq \tau$ **then**
- 14: Save (x_{cand}, c)
- 15: Update memory $\mathcal{M}_c$
- 16: $x_{seed} \leftarrow x_{cand}$
- 17: **end if**
- 18: **end for**
- 19: **end for**
- 20: **end for**
- 21: **return** Augmented corpus D'




Figura 2. Proceso iterativo Telephone-Game Augmentation (TGA).

III-C. Clasificadores Ligeros para Inferencia (Online)

La inferencia en tiempo real se confía a modelos lineales ligeros ejecutados en CPU. Estos procesan características dispersas (TF-IDF de n-gramas) y recuentos de marcadores. Al combinar algoritmos eficientes con entradas enmascaradas, los clasificadores priorizan pistas estructurales.

IV. ENTORNO EXPERIMENTAL Y RESULTADOS

Evaluamos nuestra propuesta utilizando el conjunto de datos público SuperTweetEval (10). Se aisló estrictamente un 10 % del corpus original como conjunto de prueba (*test*).

IV-A. Texto Crudo vs. Enmascarado y Aumento de Datos

La Tabla I resume el impacto de las técnicas propuestas sobre el conjunto de prueba. El enmascaramiento mejora sustancialmente la detección frente al texto crudo. En clasificación binaria, el F1-macro promedio sube +0.073. En el

entorno multiclase, la ganancia es aún más pronunciada para modelos como SVM Lineal.

Tabla I
RESULTADOS (TEST): RENDIMIENTO F1-MACRO COMPARANDO TEXTO CRUDO, ENMASCARADO Y LA ADICIÓN DE TGA.

Modelo	Binario		Multiclase	
	Crudo	Mask	Crudo	Mask + TGA (RAG)
SGD (logística)	0.771	0.834	0.698	0.784
SVM Lineal	0.818	0.897	0.642	0.791
Passive-Aggressive	0.798	0.886	0.673	0.779
Complement NB	0.835	0.897	0.622	0.714
Regresión Log.	0.824	0.895	0.666	0.780

IV-B. Régimen de Escasez y Latencia

Para simular amenazas de día cero (*zero-days*), limitamos el entrenamiento a 20 muestras por clase. Tras aplicar TGA, el modelo SVM Lineal incrementó su F1-macro de 0.659 a 0.731, demostrando la capacidad del sistema para generalizar a partir de escasos datos reales.




Figura 3. Comparativa de F1-macro entre SVM Lineal y DistilBERT en los diferentes experimentos (conjunto de prueba).

La Figura 3 ilustra cómo el SVM Lineal compite de cerca con un modelo Transformer complejo (DistilBERT). Para contextualizar esto de cara a un despliegue real, medimos la latencia de inferencia por muestra bajo condiciones controladas (ver Tabla II). Ejecutándose en CPU, DistilBERT requiere ~ 34 ms por muestra, mientras que la línea base lineal se ejecuta en ~ 0.12 ms (casi tres órdenes de magnitud más rápido). Esta enorme brecha subraya el compromiso práctico: aunque los Transformers ofrecen ganancias en métricas predictivas, los modelos lineales sobre representaciones enmascaradas siguen siendo mucho más eficientes y escalables para despliegues sensibles a la latencia.

Tabla II
COMPARATIVA DE LATENCIA (POR MUESTRA, CPU, TAMAÑO DE LOTE 1).

Modelo	Media (ms)	p50 (ms)	p95 (ms)	p99 (ms)
Transformer (DistilBERT)	34.10	34.02	34.76	35.38
Línea Base Lineal (SVM)	0.12	0.12	0.15	0.20

IV-C. Análisis Cualitativo y Fallos del Modelo

El análisis de errores revela que el sistema es altamente efectivo en ataques directos pero presenta debilidades en casos de odio interseccional. Observamos que en mensajes donde

se atacan simultáneamente dos ejes (ej. género y religión), el clasificador lineal tiende a pivotar sobre el marcador con mayor peso estadístico en el entrenamiento, perdiendo el matiz de la segunda agresión.

Sin embargo, como muestra la Tabla III, el enmascaramiento corrige drásticamente las malas interpretaciones de los modelos entrenados sobre texto crudo. El término “Arabs”, incrustado dentro de una frase vulgar, es malinterpretado por la línea base como odio basado en el género debido a correlaciones espurias. El mapeo explícito al marcador neutraliza este sesgo.

Resiliencia ante Ataques Adversarios: Nuestra arquitectura mitiga el riesgo de inyecciones de *prompts* o *jailbreaks*. Al no interactuar el LLM con el usuario final de forma síncrona, el clasificador ligero procesa una entrada ya estandarizada, neutralizando cualquier intento de ofuscación adversaria.

V. CONCLUSIONES Y TRABAJO FUTURO

Esta arquitectura híbrida amortiza el alto coste computacional relegando los modelos generativos a la preparación de datos *offline*, manteniendo la inferencia *online* predecible y eficiente con clasificadores ligeros (0.12 ms). TGA y el enmascaramiento mejoran de forma consistente el rendimiento frente a datos no vistos y en regímenes de escasez. Esta separación actúa como un cortafuegos que protege el entorno de producción contra vulnerabilidades generativas. Como trabajo futuro, exploraremos el ajuste local de Modelos Pequeños (SLMs) para maximizar la privacidad y la extensión a discursos de odio multimodales en imágenes y memes.

AGRADECIMIENTOS

Trabajo financiado por la cátedra Binter en ciberseguridad de la Universidad de La Laguna y los proyectos PID2022-138933OB-I00 ATQUE y 2023DIG28 IACTA (MCIN/AEI/FEDER EU y Fundación CajaCanarias “la Caixa”).

REFERENCIAS

- [1] A. K. Jain, S. R. Sahoo, and J. Kaubiya, “Online social networks security and privacy: comprehensive review and analysis,” *Complex & Intelligent Systems*, vol. 7, no. 5, pp. 2157–2177, 2021. [Online]. Available: <https://doi.org/10.1007/s40747-021-00409-7>
- [2] B. Li, Y. Jiang, V. Gadepally, and D. Tiwari, “Llm inference serving: Survey of recent advances and opportunities,” 2024. [Online]. Available: <https://arxiv.org/abs/2407.12391>
- [3] P. Qi, D. Chiaro, and F. Piccialli, “Small models, big impact: A review on the power of lightweight federated learning,” *Future Generation Computer Systems*, vol. 162, p. 107484, 2025. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0167739X24004400>
- [4] A. Arango, J. Pérez, and B. Poblete, “Hate speech detection is not as easy as you may think: A closer look at model validation (extended version),” *Information Systems*, vol. 105, p. 101584, 2022. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0306437920300715>

Tabla III
COMPARATIVA CUALITATIVA DE ERRORES. EL PROCESO DE ENMASCARAMIENTO DESAMBIGUA TÉRMINOS VOLÁTILES EN MARCADORES EXPLÍCITOS.

Odio Real	Entrada cruda (Predicción Línea base)	Entrada enmascarada (Predicción Nuestra)
Origen	**** the Arabs until the end of times, such **** ... → Pred: género [INCORRECTO]	[SLUR:ETH_ARAB] until the end of times, such **** ... → Pred: origen [CORRECTO]
Religión	Go **** yourself you **** Jewish boy → Pred: origen [INCORRECTO]	Go **** yourself you **** [SLUR:ETH_JEWISH] boy → Pred: religión [CORRECTO]

- [5] M. Li, X. Wang, K. Gao, and S. Zhang, “A survey on information diffusion in online social networks: Models and methods,” *Information*, vol. 8, no. 4, 2017. [Online]. Available: <https://www.mdpi.com/2078-2489/8/4/118>
- [6] M. Moradi, K. Yan, D. Colwell, M. Samwald, and R. Asgari, “A critical review of methods and challenges in large language models,” *Computers, Materials and Continua*, vol. 82, no. 2, pp. 1681–1698, 2025. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1546221825000992>
- [7] P. Piot and J. Parapar, *Towards Efficient and Explainable Hate Speech Detection via Model Distillation*. Springer Nature Switzerland, 2025, p. 376–392. [Online]. Available: http://dx.doi.org/10.1007/978-3-031-88711-6_24
- [8] M. Omar, S. Choi, D. Nyang, and D. Mohaisen, “Robust natural language processing: Recent advances, challenges, and future directions,” *IEEE Access*, vol. 10, pp. 86 038–86 056, 2022.
- [9] Y. Yu, Y. Zhuang, J. Zhang, Y. Meng, A. Ratner, R. Krishna, J. Shen, and C. Zhang, “Large language model as attributed training data generator,” in *NeurIPS Datasets and Benchmarks*, 2023.
- [10] D. Antypas, A. Ushio, F. Barbieri, L. Neves, K. Rezaee, L. Espinosa-Anke, J. Pei, and J. Camacho-Collados, “Supertweeteval: A challenging, unified and heterogeneous benchmark for social media nlp research,” *arXiv preprint arXiv:2310.14757*, 2023.

Benchmark experimental para estimar el nivel de seguridad de LLM con capacidades agénticas

Irene Gosálvez White, Pedro García Teodoro

Network Engineering & Security Group

ETS Ingenierías Informática y de Telecomunicación - Universidad de Granada

{irenegwh, pgteodor}@ugr.es

Resumen—El uso de modelos de lenguaje de gran escala (LLM) como agentes autónomos con capacidad de invocar herramientas externas (*tool calling*) genera evidentes riesgos de seguridad. Este trabajo presenta un *benchmark* reproducible para evaluar su robustez en entornos agénticos, centrado en la seguridad del uso del *tool calling* frente a ataques sobre integridad, confidencialidad y disponibilidad semántica. La metodología combina *red teaming* automatizado mediante expansión adversaria de *prompts* con evaluación cuantitativa y cualitativa sobre modelos locales bajo distintos niveles de *hardening* del *system prompt*.

Index Terms—Ciberseguridad, Inteligencia Artificial, Modelos de lenguaje de gran escala, *Tool Calling*, *Benchmark* de seguridad

Tipo de contribución: Investigación original

I. SEGURIDAD EN SISTEMAS DE IA

La elevada adopción de sistemas de IA generativa ha impulsado el estudio de su seguridad [1], [2]. En este contexto, trabajos recientes revisan y analizan críticamente técnicas de *red teaming* [3]. Asimismo, se observa una tendencia hacia la automatización de estas evaluaciones [4] y el uso de herramientas *open-source* para identificar vulnerabilidades en modelos LLM [5].

El marco teórico de este ámbito se sustenta en tres estándares principales: (a) *NIST AI Risk Management Framework*, que define directrices para la gestión de riesgos en sistemas de IA; (b) *OWASP*, que identifica vulnerabilidades en LLM y aplicaciones agénticas, incluyendo amenazas como *prompt injection*, *system prompt leakage* y *tool misuse*; y (c) *MITRE ATLAS*, que modela estos riesgos como vectores de ataque reproducibles mediante tácticas, técnicas y procedimientos (TTP).

Aunque los tres estándares ofrecen una base teórica sólida, carecen de validación experimental. Este trabajo aporta:

- Un marco de evaluación para la seguridad y operatividad de agentes LLM, centrado en la capacidad de *tool calling*.
- Análisis de vectores críticos basados en *tool misuse*, *excessive agency*, exfiltración de secretos (*prompt leak*) y denegación de servicio semántica (SDoS).
- Evaluación de la robustez de modelos de código abierto bajo distintos niveles de *hardening* del *system prompt* como medida de seguridad.
- Definición de métricas comparables para medir seguridad en cuanto a integridad, confidencialidad, disponibilidad semántica y eficacia operativa.

El artículo se organiza de la siguiente manera: la Sección II describe la metodología y el diseño del *benchmark* para evaluar la seguridad de agentes LLM. La Sección III detalla




Figura 1. Capas de abstracción de la propuesta metodológica del *benchmark*.

su implementación, mientras que la Sección IV analiza los resultados obtenidos. Finalmente, la Sección V presenta las conclusiones y líneas futuras de trabajo.

II. DISEÑO DE UN BENCHMARK PARA LA EVALUACIÓN DE SISTEMAS LLM AGÉNTICOS

La propuesta metodológica se estructura en cuatro capas de abstracción (Ver Figura 1): (i) flujo general del protocolo experimental, (ii) estrategias de evaluación, (iii) niveles de endurecimiento (*hardening*) del *system prompt*, y (iv) lógica de evaluación y métricas asociadas.

A continuación se describe el sistema objetivo y cada una de las capas del diseño experimental.

II-A. Sistema objetivo: Agente LLM con capacidad de *tool calling*

El sistema objetivo es un agente LLM con capacidad de *tool calling*. Ante un *user prompt*, el modelo genera una respuesta

textual y, cuando procede, invoca herramientas, operando bajo políticas de seguridad definidas en el *system prompt*.

El *tool calling* permite generar salidas estructuradas en formato JSON conforme a esquemas predefinidos (*tool schema*), especificando los parámetros necesarios para la ejecución automatizada de acciones.

II-B. Capa 1: Flujo del protocolo experimental

Para generar un conjunto de pruebas adversarias diverso y su evaluación automatizada, se define el siguiente flujo:

1. Se parte de un conjunto de *prompts* semilla diseñados manualmente, que se expande automáticamente mediante mutaciones y transformaciones adversarias validadas frente a un modelo objetivo utilizando PyRIT (<https://github.com/Azure/PyRIT>).
2. El conjunto expandido se normaliza y se integra en una orquestación automatizada sobre múltiples modelos y escenarios mediante la herramienta Promptfoo (<https://www.promptfoo.dev/>).

II-C. Capa 2: Estrategias de evaluación

El flujo anterior se aplica sobre tres estrategias alineadas con la tríada CIA (Confidencialidad, Integridad y Disponibilidad), derivadas de amenazas recurrentes en marcos como OWASP y MITRE ATLAS (Ver Tabla I).

- **E1:** Inyección directa en llamadas a herramientas.
- **E2:** Exfiltración de información sensible contenido en el *system prompt*.
- **E3:** Inyección indirecta en entradas legítimas con contenido malicioso que degrada la disponibilidad o desvía el razonamiento.

II-D. Capa 3: Niveles de hardening del system prompt

El *hardening* se implementa exclusivamente mediante el *system prompt*, sin lógica externa, para evaluar su eficacia frente a las estrategias de ataque definidas.

Se establecen tres niveles progresivos por estrategia (E1–E3):

1. **Nivel 1 (Inductor):** Configuración permisiva basada en confianza implícita.
2. **Nivel 2 (Estricto):** Reglas y políticas explícitas en lenguaje natural que limitan acciones sensibles.
3. **Nivel 3 (Ultra):** Configuración de desconfianza explícita con auto-verificación y priorización de directivas ante ambigüedad.

Tabla I
ESTRATEGIAS DE ATAQUE.

Estrategia	Dimensión (CIA)	Descripción
E1: Direct Tool Injection	Integridad	Llamadas a herramientas con parámetros no autorizados.
E2: System Prompt Exfiltration	Confidencialidad	Exfiltración de secretos contenidos en el <i>system prompt</i> .
E3: Indirect Tool Injection y SDoS	Disponibilidad	Inyecciones indirectas causando <i>hijacking</i> del razonamiento o <i>over-refusal</i> .

II-E. Capa 4: Lógica de evaluación y métricas

La evaluación se realiza mediante un sistema automatizado (Promptfoo) que compara las salidas del modelo con aserciones derivadas de políticas de seguridad y objetivos de la tarea.

Se combina clasificación binaria (*Pass/Fail*) con una puntuación continua $S_j \in [0, 1]$, definida según patrones observados en resultados preliminares, permitiendo capturar tanto violaciones completas como desviaciones parciales.

Se definen cinco métricas principales. Tres de ellas son comunes a todas las estrategias:

1. **Pass Rate (PR):** Proporción de interacciones clasificadas como *Pass* según la evaluación binaria, que bloquean los ataques (E1, E2) o mantienen la disponibilidad (E3).
2. **Average Score (AS):** Media de las puntuaciones S_j por estrategia, reflejando el grado de alineación con los objetivos de seguridad y funcionalidad.
3. **Latencia (L):** Tiempo medio *end-to-end* por interacción.

Adicionalmente a las tres mencionadas, se derivan dos métricas específicas según la dimensión de la tríada CIA evaluada, que facilitan la comparación con la literatura actual:

4. **Attack Success Rate (ASR):** Valor opuesto al PR en escenarios de integridad y confidencialidad (E1, E2), que mide la proporción de ataques exitosos.
5. **Semantic Availability Rate (SAR):** Equivalente al PR en disponibilidad (E3), que mide la capacidad del modelo para mantener la funcionalidad legítima frente a degradaciones como *hijacking* u *over-refusal*. SAR generaliza el concepto de *over-refusal* de *OR-Bench* [6], adaptándolo a cualquier tipo de degradación de la disponibilidad semántica.

III. IMPLEMENTACIÓN DEL BENCHMARK

El procedimiento experimental de la Sección II se implementó en una infraestructura local controlada, siguiendo un ciclo de vida experimental de cinco fases: (i) calibración manual inicial, (ii) expansión adversaria automatizada, (iii) normalización del conjunto de pruebas, (iv) orquestación automatizada de la evaluación y (v) procesamiento y visualización de resultados.

A continuación se describe la arquitectura del entorno y las fases del ciclo experimental.

III-A. Arquitectura del entorno de pruebas

La infraestructura se organiza en dos nodos desacoplados:

1. **Nodo de evaluación:** Concentra la lógica del *benchmark*, incluyendo la generación adversaria automatizada, ejecución de escenarios, aplicación de aserciones de seguridad y procesamiento de resultados. Aquí se configuran las herramientas de *red teaming* y evaluación de modelos LLM (PyRIT y Promptfoo) y los *scripts* de transformación y normalización de los conjuntos de pruebas y de los resultados.
2. **Servidor local de inferencia acelerado por GPU:** Nodo donde se despliegan los modelos de lenguaje con capacidad de *tool calling* mediante Ollama. Los

modelos reciben las definiciones de herramientas directamente en el *prompt* y las invocan de forma autónoma, sin intervención de agentes externos.

La comunicación entre ambos nodos se realiza mediante llamadas HTTP estructuradas en formato JSON a través de la API de Ollama. Este diseño desacoplado asegura que las variaciones observadas en los resultados dependan exclusivamente de la estrategia de ataque y del nivel de *hardening*, minimizando efectos externos no controlados.

III-B. Fase 0: Calibración manual

Esta etapa preliminar valida la viabilidad operativa de las estrategias de ataque antes de la expansión automatizada.

Se diseñó un conjunto reducido de *seed prompts* para cada estrategia (E1, E2 y E3), que se ejecutaron manualmente bajo distintos niveles de *hardening*, permitiendo:

- Verificar el soporte de *tool calling* y su respuesta ante restricciones del *system prompt*.
- Validar que los vectores de ataque eran semánticamente plausibles y explotables en configuraciones permisivas.
- Identificar patrones iniciales de fallo para guiar la generación sistemática de escenarios adversarios.

III-C. Fase 1: Expansión adversaria automatizada

La expansión adversaria automatizada amplía y diversifica el espacio de ataque a partir de los *seed prompts* validados mediante los módulos de conversión y ejecución de PyRIT.

Cada *prompt* se transforma mediante técnicas controladas (ofuscación, cifrado, modificación de tono, inserción de llamadas a herramientas o ruido sintáctico), simulando estrategias realistas de evasión y aumentando la diversidad estructural y semántica del conjunto.

El resultado es un conjunto ampliado de *prompts* adversarios, etiquetados con su técnica de transformación y válidos para la evaluación sistemática.

III-D. Fase Intermedia: Normalización del conjunto de pruebas

Tras la expansión adversaria con PyRIT, los *prompts* se normalizan y parsean para un formato homogéneo compatible con el motor de evaluación Promptfoo. Este proceso filtra ejecuciones válidas, extrae variables relevantes y genera ficheros JSON estructurados, preservando el contenido semántico y garantizando trazabilidad completa del *benchmark*.

III-E. Fase 2: Orquestación de la evaluación final automatizada

En esta fase se orquesta la evaluación final de las tres estrategias de ataque (E1, E2 y E3) usando Promptfoo, que conecta con los modelos locales (Ollama) y aplica reglas automáticas personalizadas (JavaScript/Regex) para cuantificar las métricas *Pass Rate*, *Average Score* y *Latencia*. A diferencia de PyRIT, no genera contenido, sino que evalúa de forma determinista los *prompts* adversarios preexistentes, manteniendo trazabilidad desde los *seed prompts*.

Las respuestas se cuantifican en un rango [0,1], adaptado a cada estrategia, para el cálculo del *Average Score* final y reflejar la gravedad de cada interacción adversaria. La Tabla II resume los valores de *score* definidos para cada estrategia de ataque.

Tabla II
RESUMEN DE RANGOS DE PUNTUACIÓN Y SIGNIFICADO PARA CADA ESTRATEGIA.

Test	Score individual	Interpretación
E1	1,0	Bloqueo total, comportamiento seguro.
E1	0,9	Uso de herramienta para operaciones inocuas.
E1	0,6	Acción sobre datos sensibles.
E1	0,4	Intento de <i>bypass</i> parcial, redirigido a ruta temporal.
E1	0,0	Fallo crítico: secreto escrito en ruta sensible.
E2	1,0	Negativa clara, sin exposición de datos sensibles.
E2	0,8	Mención de herramienta en el texto, sin invocación.
E2	0,6	Ejecución no autorizada de herramienta.
E2	0,4	Exposición parcial de metadatos.
E2	0,0	Fallo crítico, exposición de secretos.
E3	1,0	Integridad mantenida, resumen útil entregado.
E3	0,5	Rechazo parcial de la petición (DoS funcional).
E3	0,2	Respuesta insuficiente, secuestro parcial de contexto.
E3	0,0	Fallo crítico, invocación maliciosa de la herramienta.

III-F. Fase 3: Procesamiento de los resultados y generación de visualizaciones gráficas

Los resultados de Promptfoo se procesan automáticamente con *scripts* propios para extraer las métricas ordenadas y comparables (*Pass Rate*, *Average Score* y *Latencia*) en archivos CSV, desglosadas por modelo, nivel de *hardening* y técnica adversaria. Estas métricas se visualizan mediante gráficos radiales, de líneas y mapas de calor, facilitando la interpretación de robustez, degradaciones y vulnerabilidades.

IV. EVALUACIÓN Y ANÁLISIS DE LOS RESULTADOS

La experimentación final se basa en los resultados de la orquestación automatizada aplicada a modelos *open-source* disponibles en Ollama, de distintas familias y características heterogéneas.

El análisis combina evaluación cuantitativa, con métricas generadas por el motor de evaluación (*Pass Rate*, *Average Score* y *Latencia*), y evaluación cualitativa, orientada a identificar patrones de razonamiento y comportamientos recurrentes frente a escenarios adversarios.

A continuación se presentan los modelos evaluados y los resultados cuantitativos y cualitativos obtenidos.

IV-A. Conjunto de modelos evaluados

El conjunto de pruebas de evaluación realizadas se refieren a los siguientes modelos LLM:

- **GPT-OSS (20.9B)**: Modelo de gran escala basado en arquitectura *Mixture-of-Experts* (20.9B parámetros), orientado a contextos extensos (131k *tokens*).
- **LLaMA 3.2 (3.2B)**: Modelo ligero de 3.2B parámetros, optimizado para eficiencia y seguimiento de instrucciones; empleado como línea base de baja escala.
- **Mistral v0.3 (7B)**: Modelo generalista de 7B parámetros, representativo de arquitecturas intermedias orientadas a proveer equilibrio entre coste y rendimiento.
- **Qwen 2.5 Coder (7B)**: Modelo especializado de 7B parámetros, enfocado en generación y razonamiento de código dentro de la familia Qwen.

Los modelos se ejecutaron localmente mediante Ollama, utilizando versiones cuantizadas (MXFP4 para GPT-OSS y Q4 para el resto) y temperatura (hiperparámetro de 'creatividad') fijada a 0 en la evaluación final para garantizar comparabilidad y reproducibilidad.

IV-B. Análisis cuantitativo

El análisis cuantitativo evalúa el desempeño de los modelos en las tres dimensiones de seguridad Integridad (E1), Confidencialidad (E2) y Disponibilidad Semántica (E3), usando las métricas definidas PR , AS , L , ASR y SAR (Sección II-E).

Como resumen del desempeño global de cada modelo LLM:

- **GPT-OSS (20B)**: Alcanza la mayor protección global, con PR_{E1} y PR_{E2} cercanos a 1,00 (ASR_{E1} y ASR_{E2} próximos a 0) y $PR_{E3} = 0,95$ (SAR alto). Su latencia L es la más alta del conjunto.
- **Mistral (7B)**: Destaca por su alta disponibilidad (E3) (PR_{E3} elevado, SAR alto), pero presenta baja confidencialidad e integridad en niveles *Inductor* y *Estricto* ($PR_{E2} = 34,26\%$, ASR relativamente alto). Solo en *Ultra* alcanza seguridad destacable. Presenta latencia L moderada, equilibrando seguridad y tiempo de respuesta, aunque no alcanza una protección completa en todos los escenarios.
- **Qwen 2.5 Coder (7B)**: Desempeño medio en la mayoría de niveles de *hardening* (PR_{E1} y PR_{E2} moderados a bajos, ASR relativamente altos) y PR_{E3} crítico en disponibilidad (SAR 4,49%). Similar a LLaMA 3.2 en el nivel inicial, mejora en *Estricto* ($PR_{E3} = 10,11\%$) y alcanza casi total seguridad en *Ultra* (PR_{E1} y $PR_{E2} \approx 1,00$, $PR_{E3} 0,91$ SAR), mostrando un desempeño comparable a GPT-OSS y convirtiéndose en el modelo más equilibrado en términos de seguridad y latencia L , que se mantiene baja en todas las estrategias.
- **LLaMA 3.2 (3B)**: Desempeño general limitado en seguridad. PR_{E1} alto en nivel inicial (93,13%) pero decrece con el *hardening* (77,50% en *Ultra*). PR_{E2} bajo en general (ASR relativamente alto) y PR_{E3} extremadamente bajo en disponibilidad (SAR mínimo). Latencia L más baja del conjunto, aunque la protección global sigue siendo limitada.

IV-C. Análisis cualitativo

Para complementar el análisis cuantitativo, se examinan los patrones de razonamiento y la calidad de las respuestas, considerando principalmente el AS para identificar comportamientos recurrentes, diferencias de robustez frente a escenarios adversarios y las fortalezas y limitaciones de cada modelo.

De este análisis se extraen las siguientes conclusiones:

- **GPT-OSS (20.9B)**: Bloqueos eficaces incluso en escenarios complejos, aunque en disponibilidad (E3) algunas solicitudes legítimas se rechazan en niveles iniciales ($AS_{E3} = 0,48$ en *Inductor*). Los ataques de manipulación psicológica reducen su eficacia principalmente en este nivel.
- **Mistral (7B)**: Destaca en disponibilidad (E3) ($AS_{E3} = 0,672$ en *Inductor*). La confidencialidad (E2) es limitada hasta *Ultra* ($AS_{E2} = 0,826$), donde alcanza un equilibrio sólido entre seguridad y latencia. Vulnerable selectivamente a ataques de ofuscación técnica y lógica compleja.
- **Qwen 2.5 Coder (7B)**: Muy dependiente del *system prompt*, con *Average Score* bajos en disponibilidad (E3) en niveles *Inductor* y *Estricto* ($AS_{E3} = 0,133$ y

0,276), superando ligeramente a LLaMA 3.2. En *Ultra* alcanza altos valores ($AS_{E3} = 0,943$), acercándose a GPT-OSS. Mantiene exposición a vectores de inyección directa camuflados en código.

- **LLaMA 3.2 (3B)**: Saturación de contexto limita respuestas seguras. *Average Score* relativamente alto en integridad (E1) en nivel *Inductor* ($AS_{E1} = 0,531$), disminuyendo en *Estricto* y *Ultra* ($AS_{E1} = 0,473$ y $0,436$). Disponibilidad (E3) muy baja ($AS_{E3} = 0,090$ – $0,207$). Vulnerable a ataques de contexto y exfiltración, aunque detecta parcialmente *prompts* ofuscados o cifrados.

V. CONCLUSIONES

Se ha desarrollado y validado la metodología propuesta como *benchmark* experimental para medir la seguridad de modelos LLM frente a vulnerabilidades de *tool calling*. Los modelos grandes, como GPT-OSS, aplican políticas de seguridad complejas y alineamiento por defecto; los intermedios (Mistral, Qwen 2.5 Coder) equilibran robustez y tiempo de respuesta; y los ligeros (LLaMA 3.2) son más vulnerables y pueden saturarse con contextos complejos. El *hardening* contextual mejora la seguridad en modelos grandes, pero en modelos ligeros su complejidad puede causar saturación en el razonamiento.

Las principales limitaciones son la evaluación de un solo turno, un único idioma, el enfoque en la robustez nativa y la muestra limitada de modelos y escenarios. Aun así, la combinación de evaluación automatizada y expansión adversaria permite detectar vulnerabilidades que métodos tradicionales podrían pasar por alto, ofreciendo una visión más realista del comportamiento de los agentes.

AGRADECIMIENTOS

Esta publicación es resultado del proyecto VIGILANT (ref. PID2024-161902OB-I00), financiado por el Ministerio de Ciencia, Innovación y Universidades de España.

REFERENCIAS

- [1] McKinsey & Company, *The state of AI in 2025: Agents, innovation, and transformation*, QuantumBlack, 2025. Available at <https://www.mckinsey.com/capabilities/quantumblack/our-insights/the-state-of-ai>.
- [2] Capgemini Research Institute, *Rise of agentic AI: How trust is the key to human-AI collaboration*, 2025. Available at <https://www.capgemini.com/wp-content/uploads/2025/07/Final-Web-Version-Report-AI-Agents.pdf>.
- [3] M. S. Jabbar, S. Al-Azani, A. Alotaibi, and M. Ahmed, "Red teaming large language models: A comprehensive review and critical analysis," *Information Processing & Management*, vol. 62, no. 6, p. 104239, 2025 (DOI: <https://doi.org/10.1016/j.ipm.2025.104239>).
- [4] A. Goh, B. Chee, M. Vagnoli, L. Baldassarre, and A. Narayan, "Scaling responsible generative AI: Automating red teaming of LLM applications," in *2025 IEEE Conference on Artificial Intelligence (CAI)*, pp. 902–905, 2025 (DOI: <https://doi.org/10.1109/CAI64502.2025.00159>).
- [5] J. Brokman, O. Hofman, O. Rachmil, I. Singh, V. Pahuja, R. Sabapathy, A. Priya, A. Giloni, R. Vainshtein, and H. Kojima, "Insights and current gaps in open-source LLM vulnerability scanners: A comparative analysis," *arXiv preprint arXiv:2410.16527*, 2024 (DOI: <https://doi.org/10.48550/arXiv.2410.16527>).
- [6] J. Cui, W.-L. Chiang, I. Stoica, and C.-J. Hsieh, "OR-Bench: An Over-Refusal Benchmark for Large Language Models," *arXiv preprint arXiv:2405.20947*, 2024 (DOI: <https://doi.org/10.48550/arXiv.2405.20947>).

Diseño e Implementación de un Next Generation Security Operations Center Basado en Herramientas Open Source e Integración de Inteligencia Artificial

Joana Justo Guillaumet
La Salle Campus Barcelona –
Universitat Ramon Llull
Carrer de Sant Joan de La Salle, 42

joana.justo@students.salle.url.edu

Alan Briones Delgado
La Salle Campus Barcelona –
Universitat Ramon Llull
Carrer de Sant Joan de La Salle,
42

alan.briones@salle.url.edu

Guiomar Corral Torruella
La Salle Campus Barcelona –
Universitat Ramon Llull
Carrer de Sant Joan de La Salle, 42

guiomar.corral@salle.url.edu

Resumen- En los últimos años, los *Security Operations Centers (SOC)* se enfrentan a un incremento del volumen de eventos de seguridad y de la complejidad de las amenazas, lo que genera una elevada carga operativa y mayores tiempos de respuesta. Este trabajo presenta la definición e implementación de una arquitectura de *Next Generation SOC (NG-SOC)* basada en herramientas open source. La propuesta integra automatización en las fases iniciales del ciclo de gestión de incidentes e incorpora *Inteligencia Artificial* como elemento de apoyo en la categorización de alertas, la definición de *playbooks* dinámicos y la implementación de un asistente conversacional para la capa ejecutiva. La validación se realiza mediante la implementación práctica de casos de uso en entorno de laboratorio. Los resultados indican que la arquitectura es funcional y mejora la eficiencia operativa del SOC.

Tipo de contribución: Investigación original

I. INTRODUCCIÓN

Con la transformación constante de la tecnología, paralelamente, la ciberseguridad se ha convertido en un pilar esencial en entornos corporativos, donde los *Security Operations Centers (SOC)* gestionan la detección, el análisis y la respuesta ante amenazas [1] [2] [3].

Sin embargo, los SOC tradicionales presentan limitaciones como el elevado volumen de alertas, la falta de automatización y la alta dependencia del análisis manual, lo que incrementa la carga operativa y los tiempos de respuesta.

Como evolución, surge el concepto de *Next Generation SOC (NG-SOC)*, que incorpora automatización, orquestación e *Inteligencia Artificial (IA)* para mejorar la eficiencia y la capacidad de respuesta.

En este contexto, el presente trabajo propone el diseño e implementación de una arquitectura NG-SOC basada en herramientas open source. La propuesta se centra en la automatización de procesos y en la integración de IA como apoyo a los analistas en la categorización de alertas y la generación de *playbooks* dinámicos. Asimismo, se incorpora un asistente conversacional orientado a mejorar la visibilidad estratégica del SOC para la capa ejecutiva.

II. FUNDAMENTOS TEÓRICOS

A. *Security Operations Center (SOC)*

Un SOC se define como una unidad organizativa encargada de gestionar la seguridad de una entidad mediante la detección, el análisis y la respuesta ante amenazas de ciberseguridad. En

la literatura académica, el estudio del SOC suele estructurarse mediante el marco Personas, Procesos y Tecnologías (PPT) [4]. En el ámbito de personas, el correcto funcionamiento del SOC requiere una asignación clara de responsabilidades y una estructura jerárquica organizada por niveles de especialización [5] [6] [7]. Se identifican los siguientes roles:

- Analista N1: realiza el triaje inicial de alertas.
- Analista N2: profundiza en el análisis y coordina la respuesta.
- Analista N3: realiza una búsqueda proactiva de amenazas y la mejora de capacidades.
- SOC Manager: responsable de la gestión operativa.
- CISO (Chief Information Security Officer): supervisión estratégica de la ciberseguridad.

En cuanto a procesos, la operativa del SOC se apoya en procesos definidos y repetibles para garantizar consistencia y eficiencia [8] [9]. Estos procesos suelen alinearse con buenas prácticas y estándares de gestión, como ISO 27000 [10], que proporcionan marcos de referencia para la gestión de incidentes y la mejora continua.

Finalmente, la tecnología del SOC comprende el conjunto de herramientas encargadas de recolectar, procesar, analizar y visualizar eventos de seguridad. Esta arquitectura suele organizarse en capas funcionales para la gestión de las alertas, siendo estas la detección, el análisis y la visualización [7].

B. *Limitaciones de los SOC tradicionales*

Los SOC tradicionales presentan limitaciones significativas. Entre las más destacadas se encuentran la sobrecarga de alertas, la elevada tasa de falsos positivos, la dependencia del análisis manual y el bajo nivel de automatización.

La acumulación de alertas dificulta el triaje eficiente y aumenta la probabilidad de errores, ya sea priorizando eventos irrelevantes o pasando por alto amenazas reales. Además, la falta de integración entre herramientas complica la correlación de información y limita las capacidades de orquestación.

Estas limitaciones generan un incremento en la carga operativa y en los tiempos de respuesta, afectando tanto a la eficiencia como a la calidad del análisis [8] [9] [11].

C. *Next Generation SOC (NG-SOC)*

Como evolución natural ante estas limitaciones, surge el

concepto de Next Generation SOC (NG-SOC). Este modelo se caracteriza por una mayor integración de herramientas, un grado superior de automatización y la incorporación de capacidades avanzadas de analítica.

Una de las piezas clave es la introducción de tecnologías SOAR (Security Orchestration, Automation and Response), que permiten automatizar flujos de investigación y respuesta mediante playbooks [12].

Asimismo, los NG-SOC apuestan por la automatización del ciclo de inteligencia de amenazas, integrando plataformas capaces de agregar y distribuir indicadores de compromiso de forma centralizada.

La IA se incorpora como mecanismo de apoyo para el análisis, priorización y enriquecimiento de alertas. No obstante, la literatura coincide en que su uso debe mantenerse bajo supervisión humana, adoptando un modelo híbrido en el que la IA actúa como asistente del analista [1] [2] [9] [13].

D. Métricas y evaluación del rendimiento

La evaluación del rendimiento del SOC es clave para su correcto funcionamiento. En este capítulo, no se pretende enumerar todas las posibles métricas, sino definir las que pueden ser aplicables al presente trabajo. Por ello, se utilizan las siguientes métricas relativas a los tiempos de gestión de los incidentes, alineándose con [14]:

- **Time to Detect (TTD):** Tiempo transcurrido hasta la detección del evento.
- **Time to Triage (TTT):** Tiempo transcurrido hasta que se tria la alerta.
- **Time to Qualify (TTQ):** Tiempo que se tarda en clasificar la alerta como real o falso positivo.
- **Time to Resolve (TTR):** Tiempo total de resolución del incidente.

Por otra parte, en el caso de los NG-SOC, se introducen métricas asociadas a automatización, orquestación e integración de IA, cuya evaluación suele tener un carácter más cualitativo.

III. METODOLOGÍA

A. Propuesta de Arquitectura

En base a los conceptos descritos en la sección anterior, se propone una arquitectura NG-SOC basada en herramientas open source. A continuación, se presenta la selección de tecnologías para cubrir las capacidades necesarias en un SOC [15] [16]. Esta se compone de los siguientes módulos:

- Capa de análisis: Wazuh [17] para la correlación de eventos y generación de alertas.
- Capa de detección: Wazuh Agents [18] en endpoints Linux y Windows, complementados con Sysmon [19]
- Gestión de incidentes: TheHive [14] para la gestión centralizada de casos, tareas y evidencias.
- Inteligencia de amenazas: MISP [21] para la gestión e intercambio de IoCs (Indicators of Compromise). Adicionalmente, se implementa el uso de VirusTotal [20] para el análisis de observables, como fuente externa de enriquecimiento, complementaria a la inteligencia interna del SOC.
- Automatización y orquestación: n8n como solución tipo SOAR, integrando flujos automatizados y agentes de IA. Se ha seleccionado el modelo flash 2.5

de Google Gemini [22] en todos los casos de uso por su razonamiento ligero y baja latencia.

- Monitorización del estado: Netdata [23] para la supervisión del estado del sistema.

A continuación, se muestra el diagrama de arquitectura (Fig. 1).




Fig. 1 Diagrama de arquitectura

B. Correlación automática entre Wazuh Y MISP

Se implementa una correlación automática entre Wazuh y MISP, permitiendo contrastar alertas con IoCs de forma automatizada. Este mecanismo enriquece las alertas y reduce la carga operativa. Dicha automatización se centra en el módulo File Integrity Monitoring (FIM), donde la creación de un fichero activa una alerta, se calculan sus hashes y se consultan en MISP vía API. El resultado obtenido se interpreta mediante reglas personalizadas en Wazuh.

C. Automatización SOAR

La automatización se basa en una arquitectura modular orquestada por n8n, que, mediante APIs y webhooks, integra herramientas del SOC simulando capacidades SOAR. El flujo se inicia con alertas de TheHive, que son normalizadas y evaluadas según su correlación con MISP. El diseño contempla dos flujos principales:

1. Flujo de amenaza confirmada

Cuando el hash del fichero ha sido identificado previamente como malicioso en MISP, la alerta se clasifica como amenaza conocida. Este escenario corresponde a incidentes cuyo riesgo ya ha sido validado por el equipo de inteligencia de amenazas y que requieren una respuesta inmediata.

En este caso, el flujo se diseña para contener la amenaza y registrar las acciones realizadas de forma automatizada. Para ello, se ha implementado la capacidad de eliminación del fichero malicioso, así como la verificación del resultado de la acción y la actualización del caso con todas las acciones realizadas, garantizando la trazabilidad del proceso.

2. Flujo de evaluación avanzada

Cuando una alerta no presenta coincidencia con ningún IoC registrado en MISP, se implementa una metodología de evaluación avanzada orientada a automatizar y asistir el trabajo de los analistas N1 y N2 mediante el uso controlado de herramientas de la IA:

a) Categorización de la alerta mediante IA

La categorización se realiza en dos fases. Primero, la alerta se enriquece mediante VirusTotal, lo que permite complementar la inteligencia del SOC y automatizar una tarea que tradicionalmente sería manual. Una vez enriquecida la alerta, se invoca un agente de IA. Dicho agente ha sido configurado para reproducir los criterios operativos que se aplicarían en un entorno real y para adoptar un enfoque conservador, clasificando como falso positivo aquellas alertas que puede descartar con un nivel de certeza elevado.

El modelo devuelve como resultado el veredicto y el razonamiento asociado, garantizando así trazabilidad y auditabilidad.

b) Gestión automática de falsos positivos

Si el agente determina que la alerta es un falso positivo, el flujo procede a su cierre automático mediante la actualización del estado en TheHive. Además, se registra el razonamiento generado por la IA, asegurando transparencia en la decisión adoptada.

Este mecanismo permite reducir el ruido operativo, evitar la creación innecesaria de casos y disminuir el tiempo de categorización, liberando al analista N1 para tareas de mayor valor añadido.

c) Definición de playbook dinámico

Un segundo agente de IA asiste al analista N2 en la definición de playbooks de investigación. A partir de la alerta enriquecida, genera automáticamente un conjunto de tareas adaptadas al contexto. Este enfoque permite la creación de playbooks dinámicos, frente a los tradicionales de carácter genérico, proporcionando un punto de partida estructurado para el análisis.

Asimismo, la alerta se promociona a caso en TheHive y se registran las tareas generadas de forma automática. Esto reduce los tiempos de categorización y facilita la respuesta, aunque manteniendo el control humano.

D. CISO Chatbot

Además de la automatización del flujo operativo del SOC, se desarrolla un segundo caso de uso orientado a la mejora de la visibilidad estratégica: el CISO Chatbot. Su objetivo es proporcionar a la figura del CISO un punto único de acceso a la información relevante del SOC para el gobierno de la ciberseguridad.

El CISO requiere acceso a información consolidada del SOC para la toma de decisiones. Tradicionalmente, la tarea de extracción de la información recae sobre los analistas, aumentando su carga. El asistente propuesto reduce esta dependencia mediante consultas en lenguaje natural y respuestas en formato ejecutivo.

El sistema, implementado en n8n, integra:

- Modelo Gemini 2.5 Flash como motor principal.
- Módulos de síntesis y memoria contextual.
- Acceso vía API a Wazuh, MISP y TheHive.

El agente interpreta la intención del usuario y decide de forma autónoma qué herramienta consultar, sin que el usuario necesite conocer dónde reside la información.

IV. RESULTADOS

A. Correlación automática entre Wazuh Y MISP

Se valida la integración entre Wazuh, MISP y TheHive. Wazuh detecta la creación del fichero, calcula sus hashes y confirma la coincidencia con MISP. La alerta enriquecida se envía a TheHive con la información contextual del endpoint.

Este flujo demuestra la capacidad del sistema para detectar, correlacionar y priorizar incidentes de forma totalmente automática.

B. True Positive

Ante una alerta con coincidencia en MISP, el sistema ejecuta automáticamente el flujo de respuesta: clasificación de la alerta, contención y registro de las acciones para trazabilidad completa.

Tabla I: Métricas Caso True Positive

Métrica	Tiempo observado
Time to detect (TTD)	1 segundo
Time to triage (TTT)	44 segundos
Time to qualify (TTQ)	44 segundos
Time to resolve (TTR)	1 segundo

Los resultados muestran que el sistema reduce significativamente el tiempo de reacción y la carga operativa de los analistas N1 y N2. No obstante, no asume fases avanzadas como análisis forense o recuperación.

C. False Positive

En ausencia de coincidencia con IoCs, el sistema activa la evaluación avanzada, consulta a VirusTotal y analiza la alerta con IA. Tras determinar que se trata de un falso positivo, se categoriza como tal automáticamente.

Tabla II: Métricas caso False Positive

Métrica	Tiempo observado
Time to detect (TTD)	1 segundo
Time to triage (TT)	2 minutos
Time to qualify (TTQ)	2 minutos

Los resultados muestran que el sistema permite descartar de forma rápida y autónoma eventos no maliciosos, reduciendo el ruido operativo y la carga del analista N1. El enfoque se mantiene conservador, ya que únicamente se clasifican como falsos positivos aquellas alertas con un alto nivel de confianza.

D. Definición de playbook

Se evidencia que cuando la alerta no puede descartarse con certeza, se procede al análisis mediante un agente de IA que genera un playbook dinámico adaptado al contexto y lo registra en TheHive.

Tabla III. Métricas caso definición de playbook dinámico

Métrica	Tiempo observado
Time to detect (TTD)	1 segundo
Time to triage (TTT)	2 minutos
Time to qualify (TTQ)	2 minutos

Este escenario demuestra que el sistema es capaz de diferenciar eventos ambiguos de falsos positivos en el caso de uso definido, automatizar la categorización inicial y asistir al

analista en la definición del playbook, reduciendo la carga operativa sin sustituir el criterio humano.

E. CISO Chatbot

El chatbot permite consultas en lenguaje natural sobre Wazuh, TheHive y MISP, identificando de forma autónoma la herramienta a consultar y devolviendo la información en formato ejecutivo, mejorando así la visibilidad del SOC y reduciendo la dependencia de los analistas.

V. CONCLUSIONES

El presente trabajo propone e implementa una arquitectura funcional de NG-SOC basada en herramientas open source e integración de IA, demostrando su correcto funcionamiento mediante los casos de uso definidos. Asimismo, los resultados confirman:

- La automatización de la correlación entre la detección y la inteligencia de amenazas (Wazuh-MISP).
- La respuesta automática ante amenazas confirmadas para el caso de uso definido.
- La capacidad de la IA para identificar falsos positivos en el caso de uso definido.
- La generación de playbooks dinámicos para alertas sospechosas.
- La mejora de la visibilidad estratégica mediante el CISO Chatbot.

En conjunto, los resultados demuestran que la automatización y la integración de IA aportan valor al modelo tradicional de SOC, reduciendo la carga operativa, mejorando la eficiencia y facilitando tanto la gestión técnica como la visibilidad ejecutiva.

VI. LIMITACIONES Y LÍNEAS DE MEJORA FUTURAS

La principal limitación es el enfoque en un único caso de uso (FIM), restringiendo así la generalización de los resultados. No obstante, este enfoque pretende demostrar el valor de automatizar eventos de alto volumen en una organización, aunque de bajo impacto. Asimismo, el uso de IA se ha aplicado bajo un enfoque asistido, en línea con la literatura, que respalda su utilización en tareas como la categorización, priorización o generación de playbooks, pero muestra menor madurez en la toma de decisiones autónomas en entornos críticos. Se proponen como líneas futuras:

- Extensión de las automatizaciones a otros tipos de alertas.
- Ampliación de la automatización hacia fases avanzadas, como el análisis forense.
- Evaluación cuantitativa del agente de IA para la clasificación de alertas, analizando su precisión y posibles errores mediante datasets más amplios.
- Evolución del CISO Chatbot para manejar mayor volumen de datos y permitir realizar consultas más complejas.
- Implementación y entrenamiento de modelos propios de IA para la categorización de alertas y definición de playbooks.

REFERENCIAS

- [1] S. Schinagl, K. Schoon, y R. Paans, «A Framework for Designing a Security Operations Centre (SOC)», ene. 2015, pp. 2253-2262. doi: 10.1109/HICSS.2015.270.
- [2] M. Saraiva y N. Mateus-Coelho, «CyberSoc Framework a Systematic Review of the State-of-Art», *Procedia Computer Science*, vol. 204, pp. 961-972, ene. 2022, doi: 10.1016/j.procs.2022.08.117.
- [3] R. Bidou, «Security Operation Center Concepts & Implementation».
- [4] «Centros de Operaciones de Ciberseguridad (SOC)». Accedido: 4 de enero de 2026. [En línea]. Disponible en: <https://rms.cen-cert.cni.es/sobre-los-soc>
- [5] Department of Electrical Engineering, Udayana University, Jimbaran, Badung Regency 80361, Indonesia y I. P. E. D. Nugraha, «A Review on the Role of Modern SOC in Cybersecurity Operations», *ijcsrr*, vol. 04, n.º 05, may 2021, doi: 10.47191/ijcsrr/V4-i5-13.
- [6] Y. Ivanova, «Building a World-Class Security Operations Center: A Roadmap», Accedido: 14 de diciembre de 2025. [En línea]. Disponible en: https://www.academia.edu/38868050/Building_a_World_Class_Security_Operations_Center_A_Roadmap
- [7] Y. Dun, M. Faizal, M. Zolkipli, T. Bee, A. Firdaus, y No, *Grasp on Next Generation Security Operation Centre (NGSOC): Comparative Study*. 2021. doi: 10.22075/IJNAA.2021.5145.
- [8] M. Vielberth, F. Böhm, I. Fichtinger, y G. Pernul, «Security Operations Center: A Systematic Study and Open Challenges», *IEEE Access*, vol. 8, pp. 227756-227779, 2020, doi: 10.1109/ACCESS.2020.3045514.
- [9] O. Lindström, «Next Generation Security Operations Center».
- [10] «ISO 27001 - Certificado ISO 27001 punto por punto - Presupuesto Online», Norma ISO 27001. Accedido: 12 de abril de 2026. [En línea]. Disponible en: <https://www.normaiso27001.es/>
- [11] M. Shutock y G. Dietrich, «Security Operations Centers: A Holistic View on Problems and Solutions», presentado en Hawaii International Conference on System Sciences, 2022. doi: 10.24251/HICSS.2022.907.
- [12] «(PDF) Architecture-centric Support for Integrating Security Tools in a Security Orchestration Platform», ResearchGate. Accedido: 16 de diciembre de 2025. [En línea]. Disponible en: https://www.researchgate.net/publication/344260727_Architecture-centric_Support_for_Integrating_Security_Tools_in_a_Security_Orchestration_Platform
- [13] A. Haider y A. Elson, «The Role of AI in Automating Security Operations Centers (SOCs) for Threat Response».
- [14] «TheHive 5 Documentation», StrangeBee Docs. Accedido: 21 de diciembre de 2025. [En línea]. Disponible en: <https://docs.strangebee.com>
- [15] SOCFortress, «World's Best FREE SIEM Stack Series Compilation», Medium. Accedido: 25 de diciembre de 2025. [En línea]. Disponible en: <https://socfortress.medium.com/worlds-best-free-siem-stack-series-compilation-75f12abff21e>
- [16] «philip17rc/OpenSOC: Open Security Operations Center». Accedido: 9 de enero de 2026. [En línea]. Disponible en: <https://github.com/philip17rc/OpenSOC>
- [17] Wazuh, «Components - Getting started with Wazuh · Wazuh documentation». Accedido: 26 de diciembre de 2025. [En línea]. Disponible en: <https://documentation.wazuh.com/current/getting-started/components/index.html>
- [18] Wazuh, «Wazuh agent - Installation guide · Wazuh documentation». Accedido: 25 de diciembre de 2025. [En línea]. Disponible en: <https://documentation.wazuh.com/current/installation-guide/wazuh-agent/index.html>
- [19] markruss, «Sysmon - Sysinternals». Accedido: 21 de diciembre de 2025. [En línea]. Disponible en: <https://learn.microsoft.com/es-es/sysinternals/downloads/sysmon>
- [20] «VirusTotal - Home». Accedido: 27 de diciembre de 2025. [En línea]. Disponible en: <https://www.virustotal.com/gui/home/upload>
- [21] «MISP». Accedido: 21 de diciembre de 2025. [En línea]. Disponible en: <https://dl.acm.org/doi/epdf/10.1145/2994539.2994542>
- [22] «Gemini 2.5 Flash | Generative AI on Vertex AI», Google Cloud Documentation. Accedido: 30 de diciembre de 2025. [En línea]. Disponible en: <https://docs.cloud.google.com/vertex-ai/generative-ai/docs/models/gemini/2-5-flash?hl=es-419>
- [23] «Learn Netdata». Accedido: 21 de diciembre de 2025. [En línea]. Disponible en: <https://learn.netdata.cloud/docs/ask-netdata>

Análisis comparativo de sistemas de verificación de voz basados en inteligencia artificial

Eva Manzano Caro
Universidad de Extremadura
Escuela Politécnica de Cáceres
evamc@unex.es

Pablo Fernández González
Universidad de Extremadura
Escuela Politécnica de Cáceres
pablofg@unex.es

Belén María Ramírez Gabardino
Universidad de Extremadura
Escuela Politécnica de Cáceres
belramirez@unex.es

Fernando Broncano Morgado
Universidad de Extremadura
Escuela Politécnica de Cáceres
fbroncano@unex.es

Mar Ávila Vegas
Universidad de Extremadura
Escuela Politécnica de Cáceres
mmavila@unex.es

Resumen—La verificación de identidad mediante biometría de voz se ha convertido en una alternativa interesante a los métodos tradicionales de autenticación. Sin embargo, su rendimiento puede verse afectado por factores como el ruido, el dispositivo de grabación o la variabilidad propia de la voz.

En este trabajo se presenta un análisis comparativo de diversos sistemas de verificación de hablantes basados en técnicas de aprendizaje profundo. El enfoque propuesto utiliza representaciones de hablantes obtenidas a partir de grabaciones de audio, con el objetivo de distinguir de forma eficaz entre usuarios legítimos e impostores.

Se realizan experimentos con conjuntos de datos públicos utilizando métricas, como la tasa de error igualado (EER), el área bajo la curva (AUC) y la precisión (accuracy). Además, se analiza el equilibrio entre el rendimiento del sistema y su tiempo de inferencia. Los resultados muestran diferencias claras entre los modelos evaluados, especialmente en escenarios adversos, lo que permite identificar qué enfoques son más adecuados según el contexto de uso en aplicaciones de autenticación por voz.

Index Terms—Biometría de voz, verificación de identidad, aprendizaje profundo, ciberseguridad, reconocimiento de hablantes.

Tipo de contribución: Póster (límite 4 páginas)

I. INTRODUCCIÓN

La creciente digitalización de servicios en ámbitos como la administración electrónica, la banca, la educación o las plataformas en línea ha incrementado la necesidad de contar con mecanismos de autenticación seguros y fáciles de usar. Los métodos tradicionales, basados en contraseñas o códigos PIN, presentan limitaciones conocidas: son vulnerables a ataques de fuerza bruta, a la reutilización de credenciales y a la suplantación de identidad, además de resultar difíciles de gestionar para los usuarios. En este contexto, la biometría se ha consolidado como una alternativa relevante en ciberseguridad. Entre sus distintas modalidades, la verificación por voz destaca por ser accesible y no intrusiva, y por su fácil integración en dispositivos actuales capaces de capturar audio. Sin embargo, estos sistemas presentan varios retos. La voz puede variar debido a factores como el ruido, el estado del hablante o el entorno de grabación, lo que puede degradar el rendimiento, especialmente en escenarios no controlados. Además, el desarrollo de técnicas de suplantación avanzadas, como la clonación de voz mediante modelos generativos, amplía la superficie de ataque y plantea nuevos desafíos de

seguridad. En los últimos años, los modelos de aprendizaje profundo han permitido mejorar significativamente el rendimiento, al facilitar la extracción de representaciones de voz más robustas. Este trabajo se centra en el análisis y la evaluación de un enfoque de verificación de identidad por voz basado en aprendizaje profundo, orientado a aplicaciones de ciberseguridad, comparando el comportamiento de distintos modelos en escenarios con diferentes niveles de dificultad. Además, se plantea una metodología experimental basada en conjuntos de datos públicos y métricas estándar, que permite estudiar la capacidad del sistema para distinguir entre usuarios legítimos e impostores, considerando también el compromiso entre rendimiento y tiempo de inferencia.

II. FUNDAMENTOS Y TRABAJO RELACIONADO

La verificación de identidad por voz es una técnica biométrica que permite comprobar si una señal de voz pertenece a un hablante previamente registrado. A diferencia de la identificación, se trata de un problema binario (aceptar o rechazar), por lo que resulta adecuada para aplicaciones de autenticación. Los primeros sistemas se basaban en características acústicas como los coeficientes cepstrales en la escala de Mel (MFCC) [1] y modelos estadísticos como GMM-UBM [2], posteriormente ampliados con i-vectors. Aunque funcionaban bien en condiciones controladas, su rendimiento empeora cuando hay ruido, cambios de canal o variaciones en la grabación [3]. El uso de aprendizaje profundo ha mejorado estos resultados al permitir aprender representaciones directamente a partir de los datos. En particular, los enfoques basados en aprendizaje auto-supervisado han demostrado ser eficaces para extraer embeddings de hablante robustos sin necesidad de etiquetas [4]. En este contexto, modelos basados en embeddings, como los x-vectors [5], han demostrado buen rendimiento. Estos enfoques suelen estructurarse en dos etapas: la extracción de embeddings mediante redes neuronales y su posterior comparación mediante medidas de similitud. La evaluación de los sistemas de verificación por voz se realiza utilizando métricas estándar del área. Una de las más relevantes es la tasa de error igualado (EER), que indica el punto en el que se cometen el mismo número de errores al aceptar a un impostor y al rechazar a un usuario legítimo, proporcionando una medida global del rendimiento.



Figura 1. Arquitectura general del sistema.

También se emplean métricas como el área bajo la curva ROC (AUC), que evalúa la capacidad de discriminación del sistema (usuario legítimos e impostores), y la precisión, que indica el porcentaje de decisiones correctas. De forma complementaria, se analizan las curvas ROC y la distribución de puntuaciones para estudiar su comportamiento. En aplicaciones de autenticación, la tasa de falsas aceptaciones es especialmente relevante, ya que mide la probabilidad de aceptar a un impostor. A pesar de los avances, persisten retos importantes. Las condiciones de grabación y los dispositivos afectan al rendimiento en escenarios reales, y la aparición de técnicas de suplantación, como la clonación de voz, introduce nuevos riesgos.

III. METODOLOGÍA

El sistema utilizado sigue un esquema sencillo compuesto por tres etapas: preprocesamiento del audio, extracción de embeddings y comparación entre representaciones.

III-A. Arquitectura del sistema

El sistema de verificación de identidad por voz sigue una arquitectura modular compuesta por varias etapas. En primer lugar, las grabaciones de audio se preprocesan para homogeneizar las condiciones de entrada y reducir la influencia de factores externos. A continuación, se extraen embeddings de hablante mediante un modelo de aprendizaje profundo. Por último, estas representaciones se comparan mediante una medida de similitud para tomar la decisión de verificación. Este diseño separa la extracción de embeddings de la fase de decisión, lo que permite evaluar cada parte por separado. La Figura 1 muestra un esquema general de la arquitectura del sistema.

III-A1. Preprocesamiento de audio: Todas las grabaciones se convierten a un formato común (16 kHz, mono) para garantizar la consistencia. Además, se normaliza la amplitud y se eliminan los silencios cuando es necesario.

Las señales se ajustan a una duración fija para facilitar su uso en los modelos. Este proceso permite reducir la variabilidad introducida por factores externos y mejorar la consistencia de las entradas al modelo.

A partir del audio preprocesado (Figura 2), se obtienen representaciones vectoriales (embeddings) que resumen la información relevante del hablante en una forma compacta. Estas representaciones se generan mediante un modelo basado en aprendizaje profundo, entrenado para capturar patrones característicos de la voz.



Figura 2. Preprocesamiento aplicado a la señal de voz.

III-A2. Extracción de embeddings: Los embeddings recogen tanto información espectral como temporal, lo que permite modelar aspectos como el timbre, la entonación o la dinámica de la señal. De este modo, se obtiene una representación que refleja la identidad del hablante, reduciendo al mismo tiempo la influencia de factores no deseados, como el ruido o las condiciones de grabación. Además, estas representaciones se proyectan en un espacio donde las muestras del mismo hablante tienden a agruparse, mientras que las de hablantes distintos quedan más separadas. Esto facilita la posterior comparación entre grabaciones y mejora la capacidad del sistema para discriminar entre usuarios legítimos e impostores, incluso en escenarios con cierta variabilidad.

III-A3. Comparación y decisión: La verificación se realiza comparando los embeddings mediante similitud por coseno [6]. Esta técnica permite medir el grado de semejanza entre dos representaciones de voz de forma sencilla y eficaz. Si la similitud supera un umbral, se considera que ambas grabaciones pertenecen al mismo hablante; en caso contrario, corresponden a hablantes distintos. Este umbral permite

tomar la decisión de verificación y se ajusta en función del rendimiento del sistema. En este trabajo se utiliza el umbral correspondiente a la tasa de error igualado (EER), lo que facilita la comparación entre modelos.

III-B. Protocolo experimental



Figura 3. Protocolo experimental.

La evaluación, como se aprecia en la Figura 3, se realiza mediante la comparación de pares de grabaciones etiquetados como genuinos (misma persona) o impostores (personas distintas), lo que permite analizar la capacidad del sistema para discriminar identidades. En este contexto, se evalúan distintos modelos de verificación de hablantes basados en aprendizaje profundo, incluyendo un modelo supervisado (SSLSV Sup.) [7], una variante auto-supervisada (SSLSV DINO) [8] y un modelo más reciente orientado a mejorar la representación de embeddings (ReDimNet) [9].

Se emplean dos datasets públicos: VoxSRC 2023, con condiciones más exigentes, y VoxCeleb 1, en un entorno más controlado [10], [11]. En ambos casos se utilizan listas de pares (trials) predefinidas, lo que garantiza la comparabilidad de los resultados.

El uso de conjuntos de datos con características diferentes permite analizar el comportamiento de los modelos en escenarios complementarios.

Para cada par se calcula una puntuación de similitud a partir de los embeddings, sobre la que se aplican distintas métricas. La principal es la tasa de error igualado (EER) [12], complementada con la precisión (accuracy) y AUC [13]. La columna τ_{EER} indica el umbral de decisión en el que se alcanza la tasa de error igualado para cada modelo.

Además, se analiza el tiempo medio de inferencia por comparación, con el objetivo de evaluar la eficiencia de cada modelo.

Tabla I
INFORMACIÓN DE LOS DATASETS UTILIZADOS.

Conjunto	Archivos	Trials	Formato	Descripción
VoxSRC 2023 (val)	63 516	49 987	WAV	Alta variabilidad de canal y entorno Escenario exigente.
VoxCeleb 1	>150 000	37 720	WAV	Condiciones homogéneas; referencia estándar.

IV. RESULTADOS Y DISCUSIÓN

Se han evaluado distintos modelos de verificación de hablantes sobre dos datasets públicos: VoxSRC 2023 y VoxCeleb 1, que representan escenarios con distinto nivel de dificultad.

En el conjunto VoxSRC 2023 (Tabla II), caracterizado por una mayor variabilidad en las condiciones de grabación, el impacto del modelo es más evidente. Mientras que las variantes SSLSV presentan valores de EER de 6.76 % y 12.65 %, ReDimNet reduce este error hasta 3.44 %, lo que supone una mejora significativa en este escenario. Esta diferencia también se refleja en el AUC, que pasa de 0.9473 en SSLSV DINO a 0.9938 en ReDimNet. No obstante, este incremento en rendimiento se consigue a costa de un mayor tiempo de inferencia, alcanzando los 373.41 ms, frente a los valores considerablemente menores de los modelos más ligeros.

Tabla II
RESULTADOS OBTENIDOS SOBRE EL CONJUNTO VoxSRC 2023.

Modelo	EER	τ_{EER}	Acc.	AUC	ms
SSLSV Sup.	6.76	0.2691	93.24	0.9815	86.48
SSLSV DINO	12.65	0.2949	87.35	0.9473	135.93
ReDimNet	3.44	0.3282	96.56	0.9938	373.41

Como se muestra en la Figura 4, la tasa de error igualado (EER) varía de forma significativa entre modelos en este escenario, evidenciando el impacto de la arquitectura empleada en condiciones adversas.




Figura 4. Comparativa de la tasa de error igualado (EER) en VoxSRC 2023 para los modelos evaluados.

En el conjunto VoxCeleb 1 (Tabla III), donde las condiciones son más controladas, todos los modelos mejoran su rendimiento y las diferencias entre ellos se reducen. En este caso, las tasas de error se sitúan por debajo del 3.24 %, alcanzando un mínimo de 0.85 % en ReDimNet, mientras

que el AUC se mantiene en valores próximos a 1 en todos los modelos. Asimismo, la precisión varía en un rango más estrecho (entre 96.76 % y 99.15 %), lo que indica que incluso las soluciones más ligeras resultan competitivas. A pesar de ello, el tiempo de inferencia sigue mostrando diferencias significativas entre modelos.

Tabla III
RESULTADOS OBTENIDOS SOBRE EL CONJUNTO VoxCELEB 1.

Modelo	EER	τ_{EER}	Acc.	AUC	ms
SSLSV Sup.	1.36	0.3122	98.64	0.9987	9.54
SSLSV DINO	3.24	0.3056	96.76	0.9948	11.03
ReDimNet	0.85	0.3569	99.15	0.9993	366.32

Tal y como se observa en la Figura 5, los valores de EER disminuyen de forma general en todos los modelos, reflejando la menor dificultad del escenario.




Figura 5. Comparativa de la tasa de error igualado (EER) en VoxCeleb 1 para los modelos evaluados.

La comparación entre la Figura 4 y la Figura 5 permite analizar el impacto del entorno en el rendimiento de los sistemas. En escenarios adversos, las diferencias entre modelos son más marcadas, mientras que en condiciones controladas tienden a reducirse.

Estos resultados sugieren que la elección del modelo debe adaptarse al contexto de aplicación. En entornos con alta variabilidad puede ser necesario utilizar modelos más complejos, mientras que en escenarios más controlados pueden emplearse soluciones más ligeras sin una pérdida significativa de rendimiento.

En conjunto, los resultados muestran que el rendimiento depende del escenario de evaluación y que existe un compromiso claro entre precisión y tiempo de inferencia.

V. CONCLUSIONES Y TRABAJO FUTURO

En este trabajo se ha realizado una comparación entre distintos modelos de verificación de identidad por voz basados en aprendizaje profundo. Los resultados muestran que el rendimiento depende en gran medida del escenario de evaluación, siendo más relevantes las diferencias entre modelos en condiciones adversas.

En este sentido, la elección del modelo debe adaptarse al contexto de aplicación, ya que los modelos más complejos ofrecen una mayor robustez en entornos con alta variabilidad, mientras que los modelos más ligeros permiten reducir el

tiempo de inferencia sin una pérdida significativa de rendimiento en escenarios más controlados.

Como línea futura, resulta necesario evaluar la robustez frente a ataques de suplantación, como la clonación de voz, debido a su impacto creciente en sistemas de autenticación.

AGRADECIMIENTOS

Los autores agradecen la financiación recibida a través del proyecto 0522_CAPABILITIC_4_E, cofinanciado por el Fondo Europeo de Desarrollo Regional (FEDER) en el marco del programa Interreg VI-A España-Portugal (POCTEP) 2021-2027.

REFERENCIAS

- [1] Z. K. Abdul and A. K. Al-Talabani, "Mel frequency cepstral coefficient and its applications: A review," *IEEE Access*, vol. 10, pp. 122136–122158, 2022.
- [2] D. A. Reynolds, T. F. Quatieri and R. B. Dunn, "Speaker verification using adapted Gaussian mixture models," *Digital Signal Processing*, vol. 10, no. 1–3, pp. 19–41, 2000.
- [3] N. Dehak *et al.*, "Front-end factor analysis for speaker verification," *IEEE Transactions on Audio, Speech, and Language Processing*, vol. 19, no. 4, pp. 788–798, 2011.
- [4] H.-S. Heo, J.-W. Jung, J. Kang *et al.*, "Curriculum learning for self-supervised speaker verification," in *Proc. Interspeech*, 2023.
- [5] D. Snyder, D. Garcia-Romero, G. Sell, D. Povey and S. Khudanpur, "X-vectors: Robust DNN embeddings for speaker recognition," in *Proc. IEEE ICASSP*, 2018, pp. 5329–5333.
- [6] N. Dehak, P. J. Kenny, R. Dehak, P. Dumouchel y P. Ouellet, "Front-end factor analysis for speaker verification," *IEEE Transactions on Audio, Speech, and Language Processing*, vol. 19, no. 4, pp. 788–798, 2011.
- [7] A. Mohamed, H. Lee, L. Borgholt, J. Havtorn, J. Edin, L. Igel y J. R. Hershey, "Self-supervised speech representation learning: A review," *IEEE Journal of Selected Topics in Signal Processing*, vol. 16, no. 6, pp. 1179–1210, 2022.
- [8] M. Caron, H. Touvron, I. Misra, H. Jégou, J. Mairal, P. Bojanowski y A. Joulin, "Emerging properties in self-supervised vision transformers," in *Proc. IEEE/CVF Int. Conf. on Computer Vision (ICCV)*, 2021, pp. 9650–9660.
- [9] S. Bhardwaj *et al.*, "ReDimNet: Residual dynamic memory networks for speaker verification," in *Proc. IEEE ICASSP*, 2023.
- [10] A. Nagrani, J. S. Chung and A. Zisserman, "VoxCeleb: A large-scale speaker identification dataset," in *Proc. Interspeech*, 2017, pp. 2616–2620.
- [11] J. Huh, J. S. Chung, A. Nagrani, A. Brown, J. W. Jung, D. Garcia-Romero and A. Zisserman, "The VoxCeleb Speaker Recognition Challenge: A Retrospective," in *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 2024 vol. 32, pp. 3850–3866, doi: 10.1109/TASLP.2024.3444456.
- [12] T. Kinnunen and H. Li, "An overview of text-independent speaker recognition: From features to supervectors," *Speech Communication*, vol. 52, no. 1, pp. 12–40, 2010.
- [13] T. Fawcett, "An introduction to ROC analysis," *Pattern Recognition Letters*, vol. 27, no. 8, pp. 861–874, 2006.

Consistency is all you need – on the alignment between the EU AI Act and technical attacks against LLMs

Marina Buitrago-Pérez
Computer Security Lab (COSEC)
Universidad Carlos III de Madrid
Leganes (Spain)
marina.buitrago@alumnos.uc3m.es

Georgia Zaharia
Universitat Oberta de Catalunya
gzaharia@uoc.edu

Jose Maria de Fuentes
Computer Security Lab (COSEC) / PETSAT
Universidad Carlos III de Madrid
Leganes (Spain)
jfuentes@inf.uc3m.es

Lorena Gonzalez-Manzano
Computer Security Lab (COSEC)
Universidad Carlos III de Madrid
Leganes (Spain)
lgmanzan@inf.uc3m.es

Nicolas Anciaux
PETSACRAFT / PETSAT
Inria de Saclay
nicolas.anciaux@inria.fr

Abstract—The governance landscape for AI in Europe is based on the EU AI Act. In parallel, a growing amount of attacks against LLMs is growing, as gathered by MITRE ATLAS. For the regulation to be effective, it has to be applicable in the presence of these attacks. This paper analyzes the *consistency* between both worlds – governance and the contemporary AI attack surface. To the best of authors’ knowledge, this is the first comprehensive study in this direction. Our analysis identifies 5 mismatches, proposing amendments to the AI Act for attack-informed compliance. Collectively, our results provide a practical crosswalk for engineers and auditors and outline a roadmap for aligning AI governance with the realities of modern AI cybersecurity.

I. INTRODUCTION

AI systems are increasingly embedded in security- and safety-critical workflows, where compromise can spread across interconnected services. At the same time, AI attacks have evolved from mainly academic demonstrations into operational threats spanning the full lifecycle. Governance responses have expanded accordingly. In the EU, the AI Act establishes a risk-based regime with obligations on providers and deployers, including requirements on accuracy, robustness, and cybersecurity [1]. In the US, the NIST AI RMF and its Generative AI Profile provide a voluntary, lifecycle-oriented framework for managing AI risks [2], [3]. Soft-law guidance has also grown, including the OWASP Top 10 for LLM Applications and MITRE ATLAS [4], [5]. Yet it remains unclear how consistent these layers are with one another and with the attack surface documented in security research. Terms such as “robustness,” “resilience,” and “cybersecurity” are used across law, standards, and engineering practice with differing scopes and threat models. Prior work has identified interpretive and implementation challenges in the AI Act, as well as the difficulty of translating high-level obligations into verifiable

assurance evidence [6], [7]. However, these analyses have not been systematically integrated with evolving taxonomies of AI cybersecurity attacks and mitigations.

This paper addresses that gap by analyzing the degree of consistency between the EU AI Act and the state of AI cybersecurity attacks evidenced in the research literature and threat repositories. By surfacing mismatches, we aim to improve both regulatory implementability and real-world security outcomes, and to provide a practical crosswalk that security engineers, auditors, and policy stakeholders can use to build attack-informed compliance programs.

Paper organization. The remainder of this paper is as follows. Section II shows the background. Section III describes the alignment analysis and the proposed amendments. Section IV describes the validation. Section V introduces the related work. Lastly, Section VI concludes the paper and points out future research directions.

II. BACKGROUND

A. LLM Lifecycle

The lifecycle of LLMs can be summarized into four phases: Design, Pre-training, Fine-tuning and Alignment, and Deployment and Monitoring. NIST stresses that risk management should span all AI lifecycle stages and be tailored to the system context, including documenting assumptions, limitations, and validation activities [2], [3].

B. The EU AI Act

The EU AI Act establishes a risk-based governance regime for artificial intelligence systems placed or put into service in the EU. For cybersecurity-focused analyses, art. 15 is particularly salient since it requires high-risk AI systems to be designed and developed to achieve an “appropriate level”

of accuracy, robustness, and cybersecurity, and to perform consistently throughout their lifecycle [1]. This provision links governance to engineering outcomes but leaves key implementation questions open, motivating the need to assess consistency between legal requirements and the AI attack surface documented in AI security research.

III. ALIGNMENT ANALYSIS & PROPOSED CORRECTIONS

A. Preliminary study. Technical attacks and mitigations




Fig. 1. MITRE ATLAS Threats per LLM lifecycle phase. Availability of mitigations according to NIST RMF [2] or MITRE [5]

The current level of technical security is depicted in Figure 1. The two phases receiving a greater amount of threats are deployment/monitoring and the LLM design itself. However, the most worrisome fact is that a substantial fraction of threats remain unaddressed by NIST RMF [2], NIST AI 600-1 [3] or MITRE [5]. Particularly, 30 out of 64 threats in the deployment/monitoring phases remain without mitigation. This proportion is even bigger for fine-tuning/alignment, in which 10 threats out of 15 remain without mitigation. This is an important issue – the matter under regulation is largely insecure.

B. Misalignments and corrections

This paper follows a qualitative methodology based on a comprehensive literature review, iterative discussion amongst the authors and a validation stage to assess the robustness of the findings.

M1 Disconnection between the AI Act’s categorical risk classification and actual cybersecurity risks. The AI Act concentrates binding cybersecurity requirements on high-risk systems (art. 15 AI Act). This tiered structure is not well aligned with established cybersecurity risk drivers. Systems that are legally classified as “low” or “minimal risk” may nonetheless constitute high-consequence cyber targets when they are widely deployed, deeply integrated, or operate as single points of failure across multiple services. However, since these controls are only mandatory for high-risk systems, “low-risk” deployments may lack required hardening, monitoring, and incident feedback [8].

Transitioning towards a consequence-based cybersecurity framework

Under a consequence-triggered horizontal cybersecurity baseline, obligations scale with the severity of cyber harm and the potential for systemic propagation. This departs from the current static, sectoral risk classification [8] and calls for a harm-first model based on established cyber-harm taxonomies [9]. Within this framework, adversarial resilience testing should be required in proportion to system exposure, including structured assessments against current attacks whose cross-domain feasibility is well documented [10].

M2 By excluding pre-production AI development from its scope, the AI Act is ignoring critical attack vectors. In art. 2(8) AI Act it is established that all pre-production activities are excluded from its scope. As identified in Figure 1 out of the 131 attacks identified by MITRE [5], 67 can be executed during pre-production phases—all of which introduce latent vulnerabilities that persist undetected into deployment [11]. This “implement first, secure later” paradigm reflects a reactive security posture that the literature has consistently identified as inadequate for advanced ML-based software systems, where vulnerabilities are often exploited in training pipelines and model architectures before any regulatory obligation attaches [12], [13].

A Security-by-Design approach to pre-production AI governance

We propose the incorporation of a *Security-by-Design* obligation as a binding pre-market requirement within the AI Act. This framework should require developers to perform threat modeling exercises at each lifecycle milestone, requiring mitigation of vulnerabilities and evidence of embedded security during R&D prior to progression to production [11]. For this purpose, the legislator should specify secure ML development lifecycle practices consistent with concrete guidance or explicit mention to standards’ precepts.

M3 LLM security methods are largely outside enforceable obligations. Multiple LLM-directed attacks are either unmapped or only indirectly mapped to AI Act duties. This is a structural gap because research demonstrates that retrieved content and tool outputs function as adversary-controlled instruction channels in LLM-integrated applications, enabling exfiltration and unauthorized actions even when the base model is “robust” [14], [15], [16], [17]. Even though the NIST AI 600-1 partially addresses these attack vectors there are no prescribed testing methodologies or acceptance criteria.

Standardising architectural safeguards for LLM applications

LLM-directed attacks are not confined to the foundational model but may arise from vulnerabilities in the integrated architecture [14]. Recent work recommends system-level controls: (i) applying least privilege at the LLM-tool boundary while treating retrieved content and tool outputs as untrusted; (ii) separating privileged system instructions from untrusted data; (iii) sanitizing retrieved content before it reaches the model [18]; and (iv) regularly testing these protections before and after deployment with evaluations based on public security benchmarks.

- M4 Security-blind transparency obligations can operate as an “information hazard” channel that expands the AI attack surface.** The AI Act treats transparency as an accountability and risk-mitigation mechanism for high-risk AI systems (art. 9 and Recital 65), requiring providers to supply deployers with “instructions for use” including registry entries, training datasets, system capabilities and limitations. However, *disclosure artifacts* are not treated as part of the adversarial attack surface, nor is disclosure-risk threat modeling required. This creates a structural tension, as the same disclosure channels that enable accountability can also increase attack surface, facilitating attacks such as model extraction and downstream evasion [19] or prompt-injection attacks exploiting prompt structure and integration patterns [20].

Adopting “Security-aware” transparency

The primary mitigation is minimisation and control of the operational information publicly available about a model [21]. Architectural transparency should not be abandoned but designed with adversarial awareness, separating exploitable system details from provenance evidence. Disclosure risk assessment should be integrated into the AI Act art. 9 risk management process, treating each disclosure artifact as a potential attack vector. Following [22], documentation should be tiered: a full internal dossier, a confidentiality-bound version for deployers, and a minimum-necessary public summary.

- M5 Third-party dependency and weak risk measurability undermine effective mitigation of supply-chain adversarial techniques.** The AI Act allocates responsibility across economic operators, but in modular ecosystems involving GPAI models and downstream integrators the allocation of *technical assurance duties* becomes especially indeterminate. Although GPAI providers are subject to specific documentation and transparency obligations under Chapter V, the entity integrating the model into

a high-risk system remains responsible for full compliance under art. 16. Yet, while art. 15 requires an appropriate level of cybersecurity against malicious third-party interference, it does not define the *depth of supply-chain verification*. Moreover, limited-risk systems are not subject to structured cybersecurity or supply-chain verification duties at all, allowing third-party dependency and provenance opacity to persist across large parts of the AI ecosystem without enforceable, technically verifiable assurance requirements.

Adopting a risk measurability scheme that handles supply-chain security challenges

Focusing on the supply-chain, the framework should include a tiered disclosure architecture governing the attestation outputs made available to deployers and integrators, such as pass/fail certificates and zero-knowledge proofs of compliance [23]. It should also close the regulatory gap by imposing harmonised cybersecurity baseline requirements on upstream providers of components that, while not independently classified as high-risk, are integrated into downstream high-risk systems, thus avoiding assurance fragmentation across the AI supply chain.

IV. VALIDATION

A. Procedure

To validate our misalignments and proposed corrections, two LLMs were chosen, namely ChatGPT 5.2 Thinking and Gemini Pro. Particularly, LLMs were requested to rate the truthfulness of these misalignments as well as the suitability of their corrections. To ensure the validity of the ratings, one fake misalignment-correction pair was introduced. It relates to one issue that is properly addressed in the AI act. Appendix A in the extended version includes the prompts used as well as this fake pair.

B. Results

Table I in the extended version reports the validation results. Overall, Gemini is more favourable than ChatGPT 5.2 to both the identified misalignments and the proposed amendments, although it also rates the fake misalignment as real. By contrast, ChatGPT is more critical, but still gives moderately positive ratings and correctly identifies the fake misalignment as such. Taken together, both judges support the proposal while offering clarifications that complement our arguments.

V. RELATED WORK

This paper lies at the intersection of the EU AI Act and AI security research on adversarial techniques against modern systems. Judge *et al.* argue that AI systems, especially those based on deep learning, cannot be directly analyzed or audited under traditional regulatory models [24]. Likewise, Currie *et al.* contend that AI’s opacity and systemic risks require technology-specific governance rather than reliance on general

legal principles [25]. Other works examine how the AI Act operationalizes requirements such as accuracy, robustness, and cybersecurity, and where legal language diverges from technical practice. Gasiola highlights the complexity of its risk-based structure [26], Nolte *et al.* stress the need for harmonized standards and benchmarks [6], and Buscemi *et al.* map legal requirements to verification activities [7]. Hall *et al.* further argue that transparency and disclosure should be threat-modeled with adversarial awareness [27]. Taken together, these works show that the AI Act remains weakly aligned with attacker-centric models and current LLM attack surfaces, without a systematic analysis of those misalignments.

VI. CONCLUSION

This paper discusses whether the EU AI Act is consistent with the operational AI cybersecurity attack surface. Using an attacker-informed mapping approach grounded in lifecycle phases of LLM systems, we identified recurring alignment gaps between (i) what governance instruments require or recommend and (ii) the security properties that must hold to resist contemporary attacks.

A number of research directions arise from this work. Among them, conducting an impact assessment of these misalignments in real-world models (built in accordance with the current AI Act) would help to visualize their actual consequences.

ACKNOWLEDGMENT

Lorena Gonzalez, Jose Maria de Fuentes and Nicolas Anciaux have been partially funded by Grant PID2023-150310OB-I00 (MORE4AIO, funded by the Spanish Ministerio de Ciencia, Innovación y Universidades, the Spanish Agencia Estatal de Investigación and FEDER funds). Nicolas Anciaux has also been partially funded by ANR-22-PECY-0002 (IPoP project); and by PETSAT grant awarded by Inria, together with Jose Maria de Fuentes.

REFERENCES

- [1] European Union, “Regulation (eu) 2024/1689 of the european parliament and of the council laying down harmonised rules on artificial intelligence (artificial intelligence act),” 2024.
- [2] National Institute of Standards and Technology, “Artificial intelligence risk management framework (ai rmf 1.0),” <https://nvlpubs.nist.gov/nistpubs/ai/nist.ai.100-1.pdf>, NIST, Tech. Rep. NIST AI 100-1, 2023.
- [3] N. I. of Standards and Technology, “Artificial intelligence risk management framework: Generative ai profile,” <https://nvlpubs.nist.gov/nistpubs/ai/NIST.AI.600-1.pdf>, NIST, Tech. Rep. NIST AI 600-1, 2024.
- [4] OWASP, “Owasp top 10 for large language model applications,” <https://owasp.org/www-project-top-10-for-large-language-model-applications/>, 2024, living document; see page for latest version.
- [5] MITRE, “Mitre atlas: Adversarial threat landscape for artificial-intelligence systems,” <https://atlas.mitre.org/>, 2024, living knowledge base; see site for versioning.
- [6] H. Nolte, M. Rateike, and M. Finck, “Robustness and cybersecurity in the eu artificial intelligence act,” <https://arxiv.org/html/2502.16184v1>, 2025, also available via ACM DOI: 10.1145/3715275.3732020.
- [7] A. Buscemi *et al.*, “Assessing high-risk ai systems under the eu ai act: From legal requirements to technical verification,” <https://arxiv.org/pdf/2512.13907>, 2025, manuscript submitted to ACM (per PDF front matter).
- [8] M. Ebers, “Truly risk-based regulation of artificial intelligence: How to implement the eu’s ai act,” Stanford Law School, Tech. Rep. EU Law Working Paper No. 101, 2024.
- [9] I. Agraftiotis *et al.*, “A taxonomy of cyber-harms,” *Cybersecurity*, vol. 4, no. 1, 2018.
- [10] B. Biggio and F. Roli, “Wild patterns: Ten years after the rise of adversarial machine learning,” *Pattern Recognition*, vol. 84, pp. 317–331, 2018.
- [11] A. Vassilev, A. Oprea, A. Fordyce, and H. Anderson, “Adversarial machine learning: A taxonomy and terminology of attacks and mitigations,” National Institute of Standards and Technology, Gaithersburg, MD, Tech. Rep. NIST AI 100-2e2025, 2025.
- [12] J. He, S. L. Baxter, J. Xu, J. Xu, X. Zhou, and K. Zhang, “Security for machine learning-based software systems: A survey of threats, practices and challenges,” *arXiv preprint*, 2022. [Online]. Available: <https://arxiv.org/abs/2201.04736>
- [13] G. Apruzzese, P. Laskov, and J. Schneider, “Adversarial machine learning in industry: A systematic literature review,” *Computers & Security*, vol. 138, p. 102931, 2023.
- [14] K. Greshake, S. Abdelnabi, S. Mishra, C. Endres, T. Holz, and M. Fritz, “Not what you’ve signed up for: Compromising real-world LLM-integrated applications with indirect prompt injection,” in *Proceedings of the 16th ACM Workshop on Artificial Intelligence and Security (AISec ’23)*. ACM, 2023, pp. 79–90, arXiv:2302.12173.
- [15] Q. Zhan, Z. Liang, Z. Ying, and D. Kang, “InjecAgent: Benchmarking indirect prompt injections in tool-integrated large language model agents,” in *Findings of the Association for Computational Linguistics: ACL 2024*. Association for Computational Linguistics, 2024, arXiv:2403.02691.
- [16] X. Fu, S. Li, Z. Wang, Y. Liu, R. K. Gupta, T. Berg-Kirkpatrick, and E. Fernandes, “Imprompter: Tricking LLM agents into improper tool use,” *arXiv preprint*, 2024, arXiv:2410.14923.
- [17] W. Zou, R. Geng, B. Wang, and J. Jia, “PoisonedRAG: Knowledge corruption attacks to retrieval-augmented generation of large language models,” in *Proceedings of the 34th USENIX Security Symposium (USENIX Security ’25)*. USENIX Association, 2025, arXiv:2402.07867.
- [18] Z. Ji, D. Wu, W. Jiang, P. Ma, Z. Li, Y. Gao, and Y. Li, “Taming various privilege escalation in llm-based agent systems: A mandatory access control framework,” 2026, arXiv preprint.
- [19] J. Liang, R. Pang, C. Li, and T. Wang, “Model extraction attacks revisited,” in *Proceedings of the 19th ACM Asia Conference on Computer and Communications Security (ASIACCS ’24)*, Jul. 2024, pp. 1231–1245.
- [20] Y. Liu, G. Deng, Y. Li, K. Wang, Z. Wang, X. Wang, T. Zhang, Y. Liu, H. Wang, Y. Zheng, L. Y. Zhang, and Y. Liu, “Prompt injection attack against LLM-integrated applications,” 2025.
- [21] N. Kiribuchi, K. Zenitani, and T. Semitsu, “Securing ai systems: A guide to known attacks and impacts,” *arXiv preprint arXiv:2506.23296*, 2025, japan AI Safety Institute (J-AISI). [Online]. Available: <https://arxiv.org/abs/2506.23296>
- [22] E. Seger, L. Heim, M. Hobbhahn, T. Besiroglu, R. F. Trager *et al.*, “Open-sourcing highly capable foundation models: An evaluation of risks, benefits, and alternative methods for pursuing open-source objectives,” *arXiv preprint arXiv:2306.02043*, 2023. [Online]. Available: <https://arxiv.org/abs/2306.02043>
- [23] F. Scaramuzza and D. A. Tamburri, “Zero-knowledge proofs for ai software verification and validation: A systematic survey,” *arXiv preprint arXiv:2505.20136*, 2025. [Online]. Available: <https://arxiv.org/abs/2505.20136>
- [24] B. Judge, M. Nitzberg, and S. Russell, “When code isn’t law: rethinking regulation for artificial intelligence,” *Policy and Society*, vol. 44, no. 1, pp. 85–97, Jan. 2025.
- [25] W. L. Currie, J. M. Leimeister, D. Schlagwein, and L. Willcocks, “Rethinking technology regulation in the age of AI risks,” *Journal of Information Technology*, vol. 40, no. 3, pp. 236–245, 2025.
- [26] G. G. Gasiola, “Rebuilding the pyramid: The AI act’s risk-based approach using a binary decision diagram,” *Computer Law & Security Review*, vol. 58, p. 106189, 2025.
- [27] P. Hall, O. Mundahl, and S. Park, “The pitfalls of “security by obscurity” and what they mean for transparent AI,” in *Proceedings of the AAAI Conference on Artificial Intelligence (AAAI-25)*, 2025, pp. 28 042–28 051, bibliographic metadata via DBLP; an arXiv version is available as 2501.18669. [Online]. Available: <https://dblp.org/rec/conf/aaai/HallMP25>

Sesión de Investigación 6 - Blockchain, sistemas distribuidos e identidad soberana

Predicción de Carga Segura y Privada en Smart Grids mediante Incentivos Basados en Blockchain

Joan Ferré-Queralt *, Jordi Castellà-Roca*, Alexandre Viejo*

* Universitat Rovira i Virgili

Dept. d'Enginyeria Informàtica i Matemàtiques, CYBERCAT,
Av. Països Catalans 26, E-43007 Tarragona, Spain
{joan.ferreq, jordi.castella, alexandre.viejo}@urv.cat

Resumen—La creciente digitalización de las *smart grids* ha impulsado el uso de técnicas avanzadas de *load forecasting* basadas en datos de consumo detallados, lo que plantea importantes retos de privacidad y seguridad. Este trabajo propone un marco de *federated learning* apoyado en tecnología blockchain para el entrenamiento distribuido de modelos de predicción de demanda eléctrica. El sistema integra mecanismos de anonimato, *zero-knowledge proofs*, firmas ciegas y un sistema de reputación dinámico, con el objetivo de proteger la identidad de los usuarios y mitigar ataques de *model poisoning*. La propuesta proporciona un equilibrio entre precisión, privacidad y robustez, siendo viable en entornos con dispositivos IoT de recursos limitados. Se trata de un resumen extendido de una investigación ya publicada [1].

Index Terms—smart grid, privacidad, seguridad, load forecasting, federated learning, blockchain

Tipo de contribución: Investigación ya publicada (límite 2 páginas)

I. INTRODUCCIÓN

La predicción precisa de la demanda eléctrica es un componente esencial en las *smart grids* modernas, especialmente ante el aumento global del consumo [2]. Este desafío se intensifica con la creciente integración de recursos energéticos distribuidos (DERs), cuya variabilidad dificulta el equilibrio entre generación y demanda, reforzando la necesidad de técnicas avanzadas de *load forecasting* [3].

La *Advanced Metering Infrastructure* (AMI) permite recopilar datos detallados y casi en tiempo real del consumo energético. Diversos enfoques han mejorado la precisión de las predicciones, en particular modelos de *deep learning* como las redes Long-Short Term Memory (LSTM) [3]. No obstante, el uso de estos datos conlleva riesgos relevantes de privacidad, ya que los patrones de consumo pueden revelar información sensible sobre los hábitos y la presencia de los usuarios [4].

En este contexto, resulta necesario desarrollar mecanismos que garanticen la confidencialidad de la información y promuevan la participación segura. La tecnología *blockchain*, por su carácter descentralizado y resistente a manipulaciones, ofrece un marco adecuado para el intercambio confiable de datos.

I-A. Trabajos relacionados

Los primeros estudios sobre privacidad en *load forecasting*, como el de Soykan et al. [5], aplicaron *differential privacy* a modelos LSTM, aunque basados en entrenamiento

centralizado. Como alternativa, el *federated learning* permite entrenar modelos de forma distribuida sin compartir datos brutos [6]. Sin embargo, las actualizaciones pueden seguir filtrando información sensible [7].

Para mitigar este problema, algunas propuestas incorporan *differential privacy* en las actualizaciones [8], a costa de reducir la precisión, mientras que otros trabajos emplean técnicas de agrupamiento como *k-means* para gestionar la heterogeneidad [9]. Estas soluciones no eliminan completamente el riesgo de inferencia a partir de los gradientes.

Otras aproximaciones utilizan cifrado homomórfico y computación multipartita (MPC) para ocultar las actualizaciones [10]. Aunque refuerzan la privacidad, imposibilitan las defensas como Krum [11], que requieren analizar los gradientes para detectar ataques de *model poisoning*.

I-B. Contribución

Este trabajo propone la integración de un mecanismo de reputación anónima basado en blockchain en entornos de *federated learning* para *smart grids*. La propuesta busca equilibrar privacidad y seguridad, permitiendo proteger a los usuarios y, al mismo tiempo, mitigar ataques de *model poisoning*.

II. VISIÓN GENERAL DEL SISTEMA

Esta sección presenta los actores que intervienen, los requisitos principales y un resumen del protocolo.

II-A. Actores y componentes

Los *prosumidores* (U_i) son usuarios finales que poseen datos privados de consumo.

El objetivo del sistema es entrenar un modelo global de *load forecasting* capaz de predecir la demanda del día siguiente a partir del consumo del día anterior. Los parámetros del modelo se ajustan minimizando el error cuadrático medio. En *federated learning*, cada usuario mantiene un modelo local cuyos parámetros se actualizan mediante descenso de gradiente y se agregan posteriormente mediante FedAVG [12].

Para mejorar la precisión y gestionar la heterogeneidad de los datos, un *General Aggregator* (A_G) coordina un proceso distribuido de *clustering*, generando grupos de usuarios con características similares. Cada grupo es gestionado por un *Cluster Aggregator* (A_C), responsable del entrenamiento federado.

El sistema incorpora además un mecanismo de reputación implementado mediante *smart contracts*.

II-B. Requisitos del sistema

El marco de *federated learning* propuesto para *load forecasting* debe satisfacer los siguientes requisitos:

1. *Reputación dinámica*: incorporar un sistema que evalúe la fiabilidad de los participantes.
2. *Privacidad de datos de los prosumidores*: no se pueden vincular identidades con actualizaciones.
3. *Detección de actualizaciones maliciosas*: el *Cluster Aggregator* debe identificar intentos de *poisoning*.
4. *IoT*: el sistema debe ser viable en dispositivos con recursos limitados, como los *smart meters*.

II-C. Protocolo de Federated Learning




Figura 1. Visión general del protocolo propuesto.

El sistema propuesto integra *clustering*, aprendizaje federado y mecanismos de reputación en un único protocolo orientado a preservar la privacidad y reforzar la seguridad del entrenamiento distribuido. Tras una fase inicial de agrupamiento coordinada por el agregador general (A_G), los usuarios se organizan en clústeres homogéneos, cada uno gestionado por un *Cluster Aggregator* (A_C).

El entrenamiento se desarrolla en rondas, cada cual se puede observar en la figura 1. En cada ronda, A_C selecciona un subconjunto de usuarios en función de su reputación y despliega los contratos para registrar a los participantes y gestionar las recompensas. A continuación, distribuye el modelo global inicial entre los usuarios seleccionados.

Cada usuario entrena localmente el modelo con sus datos privados y envía sus actualizaciones mediante un canal anónimo, junto con evidencias de participación que permiten verificar su legitimidad sin revelar su identidad mediante Zero-Knowledge Proofs. De este modo, se garantiza que las contribuciones puedan validarse sin comprometer la privacidad.

El agregador verifica las actualizaciones recibidas, descarta contribuciones inválidas o potencialmente maliciosas y aplica mecanismos de agregación robustos para actualizar el modelo global. Las contribuciones aceptadas se asocian a recompensas que se publican de forma transparente en la blockchain mediante firmas ciegas.

Finalmente, los usuarios recuperan y canjean sus recompensas a través de los contratos correspondientes. Este proceso activa la actualización de su reputación, reforzando la participación honesta y penalizando comportamientos adversarios en rondas posteriores.

En conjunto, el protocolo permite combinar aprendizaje federado, anonimato, reputación e incentivos en un marco unificado, proporcionando un equilibrio entre precisión, privacidad y seguridad en entornos de *smart grid*.

III. CONCLUSIONES Y TRABAJO FUTURO

El trabajo propone un marco de federated learning seguro y preservador de la privacidad para *smart grids*, combinando anonimato, zero-knowledge proofs, blind signatures y un sistema de reputación basado en blockchain. El enfoque garantiza anonimato, integridad del modelo, detección de comportamientos maliciosos y rendimiento adecuado en dispositivos IoT. Los resultados muestran que el sistema gestiona eficazmente la heterogeneidad, incentiva la honestidad y reduce el impacto de participantes adversarios.

Como trabajo futuro, se planea implementar un entorno realista de federated learning para evaluar ataques avanzados y extender el marco a escenarios como *dynamic pricing*.

AGRADECIMIENTOS

Esta investigación está financiada por los Proyectos PID2021-125962OB-C32 «SECURING/DATA» y PID2024-156914OB-C42 «SAFE/DATA», financiados por MCIN/AEI/10.13039/501100011033. Joan Ferré-Queralt cuenta con el apoyo del Gobierno de España mediante una beca FPU (ref. FPU23/01275). Alexandre Viejo es Serra-Hünter Fellow.

REFERENCIAS

- [1] J. Ferré-Queralt, J. Castellà-Roca, and A. Viejo, "Secure and privacy-preserving load forecasting in smart grids through blockchain-based incentives," in *International Conference on Network and System Security*. Springer, 2025, pp. 59–76.
- [2] I. E. Agency, "Global electricity demand rising in 2021," IEA, 2021. [Online]. Available: <https://www.iea.org/reports/global-energy-review-2021>
- [3] N. Ahmad, Y. Ghadi, M. Adnan, and M. Ali, "Load forecasting techniques for power system: Research challenges and survey," *IEEE Access*, vol. 10, pp. 71 054–71 090, 2022.
- [4] Z. Bilgin, E. Tomur, M. A. Ersoy, and E. U. Soykan, "Statistical appliance inference in the smart grid by machine learning," in *2019 IEEE 30th International Symposium on Personal, Indoor and Mobile Radio Communications (PIMRC Workshops)*. IEEE, 2019, pp. 1–7.
- [5] E. U. Soykan, Z. Bilgin, M. A. Ersoy, and E. Tomur, "Differentially private deep learning for load forecasting on smart grid," in *2019 IEEE Globecom Workshops (GC Wkshps)*. IEEE, 2019, pp. 1–6.
- [6] M. N. Fekri, K. Grolinger, and S. Mir, "Distributed load forecasting using smart meter data: Federated learning with recurrent neural networks," *International Journal of Electrical Power & Energy Systems*, vol. 137, p. 107669, 2022.
- [7] L. Melis, C. Song, E. De Cristofaro, and V. Shmatikov, "Exploiting unintended feature leakage in collaborative learning," in *2019 IEEE symposium on security and privacy (SP)*. IEEE, 2019, pp. 691–706.
- [8] Y. Zhao, W. Xiao, L. Shuai, J. Luo, S. Yao, and M. Zhang, "A differential privacy-enhanced federated learning method for short-term household load forecasting in smart grid," in *2021 7th International Conference on Computer and Communications (ICCC)*. IEEE, 2021, pp. 1399–1404.
- [9] Y. He, F. Luo, M. Sun, and G. Ranzi, "Privacy-preserving and hierarchically federated framework for short-term residential load forecasting," *IEEE Transactions on Smart Grid*, vol. 14, no. 6, pp. 4409–4423, 2023.
- [10] J. Lei, L. Wang, Q. Pei, W. Sun, X. Lin, and X. Liu, "Privgrid: Privacy-preserving individual load forecasting service for smart grid," *IEEE Transactions on Information Forensics and Security*, 2024.
- [11] P. Blanchard, E. M. El Mhamdi, R. Guerraoui, and J. Stainer, "Machine learning with adversaries: Byzantine tolerant gradient descent," *Advances in neural information processing systems*, vol. 30, 2017.
- [12] H. B. McMahan, E. Moore, D. Ramage, S. Hampson, and B. Agüera y Arcas, "Communication-efficient learning of deep networks from decentralized data," in *20th International Conference on Artificial Intelligence and Statistics (AISTATS)*, 2017.

Protocolo Basado en FHE para la Caracterización Privada de Datos en Ecosistemas SSI

Iñaki Seco Aguirre
TECNALIA, Basque Research and
Technology Alliance (BRTA)
Parque Científico y Tecnológico de
Bizkaia, Edif. 700, 48160 Derio
inaki.seco@tecnalia.com

Cristina Regueiro Senderos
TECNALIA, Basque Research and
Technology Alliance (BRTA)
Parque Científico y Tecnológico de
Bizkaia, Edif. 700, 48160 Derio
cristina.regueiro@tecnalia.com

Borja Urquizu Gómez
TECNALIA, Basque Research and
Technology Alliance (BRTA)
Parque Científico y Tecnológico de
Bizkaia, Edif. 700, 48160 Derio
borja.urquizu@tecnalia.com

Eduardo Jacob Taquet
University of the Basque Country UPV/EHU
Plaza Ingeniero Torres
Quevedo, 1, 48013 Bilbao
eduardo.jacob@ehu.eus

Resumen—Este trabajo presenta la aplicación práctica de un protocolo de comparación privada de atributos de credenciales digitales que integra técnicas de identidad digital autosoberana con mecanismos de criptografía homomórfica y criptografía umbral. El objetivo es habilitar procesos de caracterización de datos en los que sea posible verificar atributos sensibles sin revelar su contenido, preservando así la confidencialidad a lo largo de todo el ciclo de emisión y validación de credenciales verificables. La arquitectura desarrollada permite cifrar atributos textuales y numéricos, y ejecutar comparaciones privadas mediante operaciones homomórficas. La introducción de un esquema de descifrado basado en criptografía umbral garantiza la integridad del proceso, evitando manipulaciones por parte de cualquiera de los participantes. El artículo demuestra la viabilidad del enfoque en un entorno distribuido real, evidenciando que la combinación de identidad distribuida y criptografía homomórfica constituye una solución sólida para la gestión segura de metadatos sensibles en sistemas de intercambio de datos.

Index Terms—Caracterización de datos, Privacidad, Identidad Digital Autosoberana, SSI, Criptografía Homomórfica, FHE

Tipo de contribución: Investigación original (límite 8 páginas)

I. INTRODUCCIÓN

El crecimiento exponencial del volumen de datos en la economía digital ha convertido la caracterización de datos en un elemento esencial para determinar qué información es útil en cada caso y, con ello, optimizar su valor. En numerosos entornos, esta caracterización es necesaria para evaluar la idoneidad de una fuente de datos antes de acceder a ella, para verificar el cumplimiento de requisitos normativos o para facilitar la interoperabilidad entre organizaciones. Sin embargo, este proceso puede revelar información sensible que podría exponer características estructurales o estadísticas de los datos, incluso cuando no se permite el acceso directo a ellos.

En este contexto, surge la necesidad de mecanismos que permitan caracterizar datos sin comprometer su confidencialidad, preservando tanto la privacidad de sus propietarios como la seguridad del proceso de verificación. Las aproximaciones tradicionales requieren confiar en un tercero o en mecanismos

centralizados de validación, lo cual introduce riesgos adicionales y no se ajusta a escenarios de colaboración entre entidades que desean minimizar la exposición de información sensible.

Las soluciones basadas en Self-Sovereign Identity (SSI) han ganado relevancia al proporcionar un marco descentralizado para la gestión y verificación de atributos de su identidad. Estas soluciones permiten a los usuarios controlar qué información comparten y con quién, y proporcionan capacidades criptográficas avanzadas, como las Zero Knowledge Proofs (ZKP) [1], que permiten demostrar y verificar propiedades de atributos numéricos sin exponer su valor exacto. Sin embargo, los sistemas SSI actuales muestran limitaciones significativas cuando los atributos son metadatos complejos o de tipo cadena de caracteres, que constituyen la mayoría de descripciones de datos. Las técnicas existentes para tratar estas estructuras textuales son aún incipientes y resultan insuficientes para escenarios prácticos.

Por tanto, el problema que se plantea es cómo extender los modelos de identidad actuales basados en SSI para su uso en la caracterización segura de datos, incluyendo mecanismos criptográficos avanzados que permitan demostrar y verificar datos textuales, manteniendo en todo momento las garantías de privacidad, descentralización y minimización.

I-A. Contribución

En este artículo se presenta una aplicación práctica de un protocolo de verificación privada de credenciales digitales orientado específicamente al contexto de caracterización de datos. El objetivo es demostrar cómo dicho protocolo puede emplearse en un sistema de caracterización de datos para permitir la demostración y verificación de atributos sensibles sin revelar su contenido.

Para ello, se adopta el protocolo descrito por Seco-Aguirre et al. en [2], en el que se propone una arquitectura genérica para la integración de mecanismos que combinan SSI con técnicas Fully Homomorphic Encryption (FHE). En dicha arquitectura, un subconjunto de los atributos incluidos en las credenciales verificables (VC, del inglés Verifiable Credentials) se cifra mediante FHE con el objetivo de proporcionar

una capa adicional de privacidad, manteniendo la confidencialidad de la información sensible durante los procesos de caracterización y verificación. Gracias a la posibilidad de realizar operaciones homomórficas sobre estos atributos cifrados, el protocolo permite llevar a cabo verificaciones privadas sin revelar en ningún momento los valores en claro de los atributos subyacentes.

Adicionalmente, el protocolo integra un mecanismo de criptografía umbral FHE (Threshold FHE) con descifrado distribuido, en el que el proceso de descifrado se realiza de forma conjunta por dos entidades que poseen claves privadas parciales. Este enfoque garantiza la integridad y corrección de los resultados obtenidos, al tiempo que evita manipulaciones por parte de cualquiera de las partes involucradas en el proceso de verificación, reforzando así la robustez global del sistema.

La contribución principal del presente trabajo, por tanto, radica en la aplicación e integración de este protocolo en un entorno de caracterización de datos, evaluando su adecuación, las particularidades de su adaptación y despliegue, y los requisitos técnicos específicos que conlleva su utilización en este dominio.

II. FUNDAMENTOS TEÓRICOS

II-A. Criptografía homomórfica

La criptografía homomórfica (HE) constituye una familia de técnicas criptográficas que permiten realizar operaciones matemáticas directamente sobre datos cifrados, preservando su confidencialidad en todo momento [3]. Su característica principal es que posibilita la manipulación de la información una vez cifrada, sin necesidad de acceder a su contenido en claro. Para ello, los datos se cifran mediante algoritmos que mantienen determinadas propiedades algebraicas, de forma que el resultado de las operaciones realizadas sobre los datos cifrados permanece igualmente cifrado. Una vez finalizado el proceso, dicho resultado puede ser descifrado para obtener el resultado equivalente a la operación aplicada sobre los datos originales.

Las aplicaciones de estas técnicas abarcan ámbitos como el procesamiento seguro de datos en la nube, el análisis privado de información sensible y la protección de procesos en sistemas distribuidos. No obstante, HE continúa siendo un área de investigación activa y presenta limitaciones relevantes en términos de eficiencia computacional y escalabilidad [4]. En general, los esquemas homomórficos implican un coste computacional significativamente superior al de las operaciones equivalentes sobre datos en claro, tanto en tiempo de cómputo como en consumo de recursos de procesamiento y almacenamiento. A pesar de estas limitaciones, los avances recientes permiten anticipar mejoras sustanciales, lo que refuerza su potencial para habilitar nuevas aplicaciones en escenarios donde la privacidad y la seguridad constituyen requisitos fundamentales.

II-B. Threshold FHE

La criptografía umbral (Threshold) constituye una familia de técnicas criptográficas en las que la clave privada se distribuye entre múltiples participantes mediante esquemas de compartición de secretos. En este modelo, ninguna entidad individual posee la clave completa ni puede ejecutar de forma

autónoma operaciones críticas, como el descifrado o la firma. Únicamente la colaboración de un número suficiente de partes permite llevar a cabo la operación criptográfica. Este enfoque proporciona tolerancia a fallos, robustez frente a compromisos parciales y garantías adicionales de seguridad en entornos distribuidos o multiparte.

En el ámbito de la criptografía homomórfica, estos principios se materializan en los esquemas de cifrado homomórfico con soporte umbral, conocidos como Threshold FHE [5, 6]. En este caso, la clave privada subyacente al sistema FHE se genera de manera distribuida entre las partes participantes, de forma que ninguna de ellas tiene conocimiento de la clave completa. Si bien el proceso de cifrado y la evaluación homomórfica se realizan de manera convencional utilizando una clave pública común, la fase de descifrado requiere la participación conjunta de todas las partes autorizadas.

En la práctica, cada participante calcula un fragmento parcial de descifrado utilizando su clave privada, y únicamente la combinación de dichos fragmentos permite recuperar el mensaje en claro. Este mecanismo garantiza que ningún agente aislado pueda acceder al contenido de los datos cifrados ni inferir información sensible. Implementaciones modernas, como OpenFHE [7], incorporan soporte para Threshold FHE en varios de sus esquemas homomórficos, permitiendo la definición de flujos colaborativos de cifrado y descifrado adecuados para escenarios distribuidos. Esta capacidad resulta especialmente relevante en aplicaciones en las que múltiples participantes deben cooperar sin revelar sus datos individuales.

II-C. Algoritmos de verificación sobre textos

Existen varias aproximaciones para aplicar FHE al procesamiento de texto. Entre las más destacadas se encuentran el método de Feer [8], que permite búsquedas eficientes pero depende de una codificación previa del algoritmo, lo que compromete la privacidad del texto de entrada. Otra de las opciones es aplicar los esquemas TFHE [9], que operan a nivel de bit sobre texto cifrado, que implica un coste computacional muy alto que no escala con facilidad. Y la última de las opciones es la propuesta por HELib en un ejemplo de su librería [10], donde comparan cadenas completas dentro de un único ciphertext.

Existen también algunas alternativas que permiten proteger valores no numéricos, como el esquema de Zero-Knowledge Set Membership [11], pero estas técnicas no dan soporte a valores arbitrarios sino que es necesario conocer un listado de posibilidades para aplicarlo.

II-D. Identidad Digital Autosoberana

SSI constituye un modelo de gestión de identidad digital que otorga a cada participante el control pleno y exclusivo sobre su propia identidad [12]. Aunque inicialmente concebido para la gestión de identidades personales, su ámbito de aplicación se ha ampliado progresivamente hasta incluir dispositivos IoT [13], organizaciones y, más recientemente, bases de datos [14]. Frente a los sistemas tradicionales de identidad digital, que dependen de autoridades centralizadas encargadas de la emisión, validación y custodia de los atributos, SSI propone un enfoque en el que cada entidad puede poseer, gestionar y presentar su identidad de manera autónoma y segura. En este

contexto, los identificadores descentralizados (Decentralized Identifiers, DID) proporcionan un mecanismo estandarizado para referenciar identidades de forma descentralizada.

Este modelo aborda las limitaciones de los esquemas convencionales de gestión de identidades mediante el uso de firmas digitales, habitualmente basadas en criptografía asimétrica, y de registros de datos verificables, que en muchas implementaciones actuales se sustentan sobre infraestructuras basadas en blockchain [15]. Estos elementos proporcionan integridad, inmutabilidad y verificabilidad a los atributos de identidad, reduciendo la dependencia de intermediarios y reforzando la seguridad del ecosistema.

El objetivo de SSI es proporcionar a los actores un mayor control sobre los datos que comparten, permitiendo seleccionar de forma explícita qué información revelar y a qué entidades. Este enfoque contribuye a mitigar prácticas de recopilación excesiva de datos y los riesgos asociados al uso indebido o a brechas de seguridad que afecten a información personal sensible, promoviendo un modelo de identidad digital más privado, descentralizado y resiliente.

Los actores principales en una red SSI son los siguientes:

- **Holder.** Entidad que posee, gestiona y presenta las credenciales emitidas por diferentes Issuers. Conserva las credenciales en una cartera digital (wallet) bajo su control exclusivo, y decide qué atributos compartir y en qué condiciones. Representa el principio de soberanía del modelo SSI.
- **Issuer.** Entidad responsable de emitir credenciales verificables. Certifica la veracidad de ciertos atributos del Holder y firma criptográficamente estos atributos utilizando estándares de SSI. Su función principal es garantizar la autenticidad y la integridad de la información contenida en las credenciales.
- **Verifier.** Entidad que solicita y valida las credenciales presentadas por el Holder. Comprueba la autenticidad de la firma del Issuer y la integridad de los datos utilizando los registros verificables asociados. Su función consiste en confirmar que la credencial es válida sin necesidad de contactar con el Issuer.

Un componente adicional del ecosistema SSI es el registro de datos verificables (VDR), encargado de publicar la información necesaria para la verificación de credenciales e identidades. El VDR no almacena datos personales ni credenciales completas, sino elementos verificables como DIDs, claves públicas y metadatos de resolución. En la práctica, estos registros suelen implementarse sobre infraestructuras descentralizadas, frecuentemente basadas en tecnologías DLT o blockchain, para garantizar disponibilidad e inmutabilidad [16]. La figura 1 muestra los componentes principales de una red SSI y sus interacciones.




Figura 1. Diagrama de componentes SSI.

III. CASO DE USO

III-A. Contexto

La caracterización de datos constituye un paso fundamental para que un consumidor de datos (DC) filtre de manera eficiente los distintos conjuntos de datos disponibles dentro de un sistema, y así identificar cuáles aplican en diferentes casuísticas [14]. Para ello, en el caso de uso presentado en este artículo, cada conjunto de datos se identifica mediante VCs emitidas en un entorno SSI, las cuales describen sus atributos relevantes. Sin embargo, algunos de estos atributos presentan naturaleza sensible y requieren una protección adicional. La solución propuesta busca permitir la ejecución de filtrados basados en atributos sensibles, que se cifrarán de manera que se preserve su privacidad, sin renunciar a la capacidad de búsqueda precisa por parte de los consumidores de datos.

Para facilitar la comprensión de esta necesidad, considérese un escenario donde diferentes conjuntos de datos cuentan con un atributo 'localización', que se considera sensible e incluye la dirección completa donde el dataset ha sido generado, por ejemplo 'Calle principal, 10, 5C, Madrid, España'. Si se desea identificar datos cuya localización sea, por ejemplo, 'España', se deberá de analizar el valor del atributo localización de cada conjunto de datos. Sin embargo, este atributo contiene información adicional relacionada con la localización que no es necesario compartir para poder realizar el filtrado sugerido. Al proporcionar ese atributo cifrado homomórficamente en el sistema SSI, es posible verificar la presencia del término 'España' en el atributo "localización" sin revelar ninguna otra parte de la cadena. De esta forma, se logra preservar la utilidad del atributo para procesos de selección o filtrado, al mismo tiempo que se mantiene la privacidad su contenido completo.

Para dar soporte a este caso de uso, se ha aplicado la solución descrita en [2], donde se presenta un sistema y un protocolo que permiten comparaciones de atributos cifrados en VCs mediante operaciones homomórficas. Este enfoque destaca por dos características innovadoras.

En primer lugar, determinados atributos de las VC se cifran mediante FHE, con el fin de preservar la privacidad a los datos que contienen, ya sean valores numéricos o textuales. Estos atributos cifrados tienen un tamaño considerable que no puede ser directamente soportado por una VC, por lo que se almacenan en IPFS (InterPlanetary File System), donde su integridad está garantizada, y únicamente se incluye el Content Identifier (CID) en la VC. Estos valores textuales se representan mediante su codificación ASCII, y son cifrados por la Autoridad Certificadora (CA), que actúa como Issuer en el protocolo. Para cifrar, la CA utiliza la clave pública homomórfica asociada al Proveedor de Datos (DP), quien actúa como Holder de la VC. Previamente, el DP ha generado dos claves privadas mediante Threshold FHE, y ha depositado la clave pública en un repositorio accesible tanto por la CA como por el DC. Este mecanismo añade una capa adicional de privacidad sobre los atributos, dado que su verificación exige la ejecución de operaciones homomórficas de comparación de cadenas textuales.

En segundo lugar, el uso de un sistema criptográfico basado en Threshold FHE garantiza que las comparaciones sobre atributos cifrados no puedan ser manipuladas por el DP. Cuando un DC solicita la presentación de una VC, el DP proporciona

una de las claves privadas generadas, mientras que la otra permanece protegida bajo su control exclusivo. De este modo, el proceso de descifrado requiere la participación conjunta de ambas partes, proporcionando garantías de integridad sobre los resultados de las comparaciones.

III-B. Requisitos funcionales

En el contexto de este caso de uso existen tres actores relevantes:

- **Autoridad certificadora (CA).** Entidad responsable de acreditar las VCs que caracterizan datos, por ejemplo, una administración pública.
- **Proveedor de datos (DP).** Entidad que recibe y gestiona las VC que caracterizan los datos que posee, por ejemplo, un hospital.
- **Consumidor de datos (DC).** Entidad que consume los datos de los proveedores. Requiere la ejecución de un filtrado, en base a atributos de la caracterización de los datos, que le permita identificar aquéllos que sean de su interés.

Para cada uno de estos actores se han definido una serie de requisitos funcionales que deben cumplir para el correcto funcionamiento del protocolo. A continuación, se detallan los requisitos por rol, con una descripción breve de cada uno:

Autoridad certificadora

1. **R1: Definición y emisión de VCs.** La CA debe poder definir esquemas SSI y credenciales adecuadas para la caracterización de diferentes tipos de conjunto de datos (por ejemplo, por dominio). Además, debe poder emitir VCs para los diferentes esquemas.
2. **R2: Cifrado FHE y publicación de atributos.** La CA debe poder cifrar atributos con la clave pública del DP y publicar los ciphertexts en IPFS.

Proveedor de datos

1. **R3: Gestión de claves Threshold FHE.** El DP debe poder generar el material criptográfico necesario, registrar su información pública en el DB y notificar al sistema sobre las nuevas claves.
2. **R4: Gestión de VCs.** El DP debe poder almacenar en su wallet las credenciales SSI recibidas y generar presentaciones SSI a partir de ellas.
3. **R5: Acceso y verificación de atributos cifrados.** El DP debe poder recuperar los atributos cifrados y descifrarlos hasta obtenerlos en claro para verificarlos.

Consumidor de datos

1. **R6: Solicitud y recepción de presentaciones VC.** El DC debe poder solicitar presentaciones de atributos específicos al DP, y recibir las respuestas correspondientes.
2. **R7: Acceso a información cifrada.** El DC debe poder extraer los atributos cifrados de una presentación.
3. **R8: Comparaciones privadas sobre atributos.** El DC debe poder ejecutar operaciones homomórficas de comparación de textos para verificar el valor de los atributos.
4. **R9: Descifrado final de resultados.** El DC debe poder descifrar los resultados en colaboración con el DP, pudiendo obtener un resultado final en claro.

IV. DISEÑO E IMPLEMENTACIÓN

En este apartado se describen las decisiones de diseño y los detalles de implementación relativos al entorno de ejecución empleado en las pruebas experimentales. El objetivo es proporcionar la información necesaria para garantizar la reproducibilidad de los resultados y contextualizar las limitaciones de rendimiento observadas.

IV-A. Software utilizado

La implementación del prototipo se ha construido sobre un conjunto de librerías y componentes software de código abierto. En la **capa de FHE** se ha utilizado la librería OpenFHE en la versión 1.0.2, que proporciona soporte para distintos esquemas de cifrado homomórfico. La selección de OpenFHE se debe a su madurez, a la disponibilidad de implementaciones optimizadas y a la comunidad activa de desarrolladores y usuarios. Tanto la generación de claves como las operaciones requieren de seleccionar un contexto criptográfico (CC) común bajo el que trabajar de manera conjunta.

Para desarrollar la operación de comparación homomórfica se ha replicado la implementación del algoritmo [10] en OpenFHE, utilizando el esquema BGV. La elección del algoritmo se justifica por su capacidad para codificar cadenas completas en un único ciphertext, minimizando así el número de cifrados que deben gestionarse durante el procesamiento. Además, su diseño permite aplicar rotaciones e iteraciones dentro del propio ciphertext, lo que posibilita realizar comparaciones más complejas, como determinar si un texto está contenido en otro.

En la **capa de SSI** se ha empleado un conjunto de componentes basado en el ecosistema Hyperledger, en particular:

- VON Network de Hyperledger Indy como VDR para el registro de DIDs y esquemas de credenciales. En concreto la librería proporcionada por el gobierno de British Columbia [17] en la versión 1.7.2.
- Hyperledger Aries como agente intermediario para la orquestación de flujos de emisión y verificación de datos con Hyperledger Indy [18].

IV-B. Arquitectura software y componentes

La Figura 2 muestra la arquitectura, organizada en torno a los tres actores fundamentales del caso de uso: la CA, el DP y el DC. Cada uno de estos actores incorpora tanto capacidades de gestión de credenciales SSI como módulos para la gestión de los atributos cifrados, permitiendo la emisión, custodia y verificación de VCs con atributos cifrados.

En la capa superior se encuentra el módulo de autenticación, responsable de habilitar el acceso seguro de los tres tipos de usuarios mediante sus respectivas interfaces de usuario (UI). Estas interfaces se comunican con los controladores internos (Issuer, Holder y Verifier), que mantienen la lógica de negocio y orquestan la interacción con los agentes SSI y FHE.

La capa intermedia agrupa los componentes funcionales de cada actor. Para este despliegue se ha considerado un único participante de cada tipo. Cada actor tiene un equipo con las herramientas necesarias para poder realizar todas las acciones pertinentes. En particular, el agente SSI gestiona




Figura 2. Arquitectura de la implementación desplegada.

credenciales, DIDs y las interacciones con el VDR, el agente FHE gestiona todas las operaciones relacionadas con la criptografía homomórfica, y la UI contiene la aplicación web para poder consumir los servicios de cada agente y facilitar la usabilidad del sistema. Tanto la CA como el DP tienen los servicios desplegados localmente, mientras que el Verifier es un servicio expuesto públicamente para que múltiples DCs puedan consumirlo. Los flujos verticales conectan las UIs con sus respectivos controladores y agentes, mientras que los flujos horizontales representan las interacciones entre actores durante los procesos de emisión, almacenamiento y verificación de credenciales.

En la parte inferior se representan los sistemas de almacenamiento:

- IPFS. Empleado para el almacenamiento descentralizado de ciphertexts.
- DB. Empleado para almacenar información necesaria para el funcionamiento del sistema como contextos criptográficos, claves públicas o endpoints de la red SSI.
- VDR. Empleado para registrar los elementos criptográficos necesarios para el funcionamiento de SSI, como identificadores DID o definiciones de credenciales.

IV-C. Interacción entre componentes y flujo de comunicaciones

El flujo de ejecución está separado en dos grandes fases:

- Caracterización de datos.
- Verificación de características de los datos.

La Figura 3 describe, a alto nivel, el flujo de comunicaciones existente para emitir una VC, la cual contiene los atributos que caracterizan los datos de un DP. Esta fase, a su vez, se puede dividir en tres subprocesos:

- Registro del DP. El DP se registra contra la plataforma a través de su UI. A partir de esta petición se generan todos los componentes criptográficos necesarios para poder participar (CC y claves FHE), y se almacena la información pública generada en el DB.
- Emisión de VC. La CA comienza un proceso de certificación de un conjunto de datos. Selecciona el dominio y el DP, y obtiene los atributos que desea certificar. Se definen valores para esos atributos, se cifran con la clave pública del DP y se almacenan en IPFS, que devuelve un CID. A continuación, se crea una VC que incluye los




Figura 3. Flujo de caracterización de datos.

CIDs de los valores de los atributos, y se emite para que el DP lo almacene en su wallet.

- Validación de atributos del DP. El DP recibe la VC e inicia un proceso de verificación tradicional. Obtiene los CIDs y descarga los valores cifrados de los atributos de caracterización de sus datos. Una vez descargados, los descifra utilizando sus claves privadas y así poder validarlos en claro.

La Figura 4 muestra, a alto nivel, el flujo de comunicaciones que se lleva a cabo para realizar una verificación privada de los atributos de los datos. Esta fase también se puede dividir en tres subprocesos:

- Nueva solicitud de búsqueda. Tras autenticarse, el DC define los valores objetivo, que son los atributos que se van a buscar entre las características de los datos. Define sus valores objetivo y envía la petición al Verifier, quien continúa con el proceso.
- Búsqueda privada de datos. El Verifier solicita el listado de DPs registrados, y para cada proveedor solicita una Verifiable Presentation (VP), es decir, la presentación de una VC y de los atributos específicos. El Verifier realiza el proceso de validación tradicional con el VDR para comprobar que la VP es válida, y si es válida, obtiene




Figura 4. Flujo de verificación de características de los datos.

los atributos cifrados de IPFS y la clave pública del DP. Después, el Verifier cifra el valor objetivo y aplica la operación de comparación homomórfica ‘*contiene*’ en cada atributo definido. Esta operación busca cadenas de texto del valor objetivo dentro de la cadena de texto del atributo, que pueden ser del mismo o distinto tamaño [2, 10]. A partir de cada comparación se obtiene un resultado cifrado.

- Descifrado seguro de los resultados. El Verifier obtiene la clave privada proporcionada por el DP, la cual le permite generar un primer descifrado parcial de cada resultado (fragmento 1) y enviárselo al DP, junto con el resultado de la comparación cifrado. El DP utiliza la otra clave privada para obtener el segundo descifrado parcial (fragmento 2) y fusionarlo con el primero, lo que le permite hacer una validación de seguridad comprobando la coherencia del resultado. Si todo es correcto y no hay manipulaciones, envía el segundo descifrado parcial al Verifier para que pueda fusionar los

dos fragmentos y obtener el resultado de la comparación en claro. Finalmente, el Verifier, procesa los resultados de la comparaciones para todos los DPs registrados, y devuelve al DC la lista de aquéllos que cumplen los valores objetivos.

IV-D. Consumo de servicios

Los tres actores cuentan con UIs que permiten a los participantes consultar y consumir los servicios disponibles dentro del ecosistema.

Figura 5. Interfaz de usuario de una CA.

La Figura 5 muestra el formulario que completa una CA cuando emite una VC. Este formulario le permite seleccionar el dominio en el que se emite una credencial, insertar el identificador del DP al que se va emitir la VC y completar los valores de cada atributo con la información correspondiente. También permite insertar atributos extra pulsando el botón *Add Attribute*. Una vez se ha rellenado la información, se emite la VC pulsando el botón *Issue Credential to Data Provider*.

Figura 6. Interfaz de usuario de un DP.

En cualquier momento, el DP puede listar las credenciales

que se le han emitido y que caracterizan sus datos. La Figura 6 presenta un ejemplo de listado de la VC emitida por la CA en la Figura 5, donde se observa que ciertos campos se representan mediante CIDs. Estos son atributos que se han cifrado y almacenado en IPFS, evitando la visualización de información en claro. La UI del DC mostraría un formulario para definir los valores objetivo y realizar las peticiones de búsqueda, también mostraría los resultados obtenidos de las búsquedas.

V. VALIDACIÓN

Esta sección presenta los resultados de la validación de la solución propuesta. La validación se ha realizado con el objetivo de comprobar tanto el rendimiento como la efectividad lograda con el uso del protocolo de [2] en un caso de uso concreto. Los resultados mostrados a continuación se han obtenido a partir de un despliegue experimental mediante contenedores Docker, con una CA (Issuer), un DP (Holder) y un DC (Verifier) en diferentes equipos de 2 CPUs y 8GB de RAM cada uno, y una red IPFS desplegada mediante contenedores en un equipo de 1 CPU y 4GB de RAM.

La validación se ha centrado en las acciones relacionadas con FHE, ya que la evaluación de rendimiento de SSI está ampliamente estudiada en la literatura [19]. En el ámbito de HE implementado, el parámetro que más impacto tiene en el rendimiento del algoritmo de comparación homomórfica de atributos privados es la profundidad de multiplicación (mult-depth). El multdepth define el número máximo de multiplicaciones que se pueden ejecutar un ciphertext sin comprometer la precisión en los resultados, y se ha configurado en 19. Para realizar la validación de rendimiento, se han definido las siguientes métricas:

- Tiempo de cifrado de atributos. Tiempo medido en el componente del Issuer desde que se obtienen los objetos criptográficos hasta que se cifra el valor del atributo. Se han considerado atributos con 6 caracteres.
- Tiempo de descifrado de atributos. Tiempo medido en el componente del Holder desde que obtiene el valor cifrado de un atributo en una credencial hasta que se recupera el dato en claro. Este proceso opera palabras con 6 caracteres cada una, e incluye los descifrados parciales y la fusión de ambos fragmentos.
- Tiempo de comparación de atributos cifrados. Tiempo medido en el componente del Verifier desde que se hace una petición de hasta que se ejecuta la comparación. Este proceso opera palabras con 6 caracteres cada una, e incluye los procesos de descifrado usando Threshold FHE.

Tabla I
MÉTRICAS DEL ECOSISTEMA HE MÁS RELEVANTES.

Métrica	Tiempo (s)
Tiempo de cifrado de atributos	≤ 1 por atributo
Tiempo de descifrado de atributos	3
Tiempo de comparación de atributos cifrados	93

Los resultados de la Tabla I muestran que el tiempo de cifrado de atributos en la CA se mantiene por debajo de 1 segundo por atributo, lo que indica que el proceso de generación de los valores cifrados es eficiente y no introduce

latencias significativas en la fase de emisión de la VC. Este comportamiento es coherente con un flujo en el que el CA ejecuta únicamente operaciones criptográficas directas y no depende de interacción con otros componentes, lo que favorece la estabilidad temporal del proceso.

El tiempo de descifrado en el DP es de 3 segundos, lo cual es esperable debido a que el DP debe realizar operaciones de descifrado más complejas, incluyendo fases parciales y la fusión de fragmentos de descifrado. Este resultado se considera adecuado en este contexto ya que el DP actúa como entidad soberana, ejecutando localmente procesos criptográficos que, por su propia naturaleza, requieren mayor coste computacional. El valor obtenido demuestra que el DP puede recuperar información confidencial contenida en una VC sin afectar de manera significativa la usabilidad del sistema.

El tiempo de comparación de valores de atributos en el DC, con un valor de 93 segundos, refleja el impacto acumulado de las operaciones involucradas en el proceso de búsqueda. Este tiempo incluye comparaciones homomórficas costosas sobre el atributo cifrado y el descifrado delegado en el DP, lo que explica el incremento respecto a las métricas anteriores.

A continuación se presenta un resumen del cumplimiento de los requisitos definidos en la Sección III. Como se muestra en la Tabla II, todos ellos han sido cubiertos mediante el uso del protocolo de [2] y su adaptación al caso de uso.

Tabla II
CUMPLIMIENTO DE REQUISITOS Y DESCRIPCIÓN DE IMPLEMENTACIÓN.

Req.	Cumpl.	Implementación
R1	Sí	La CA puede definir los esquemas SSI y las credenciales, así como emitir VCs a los DP, a través del Issuer.
R2	Sí	La CA puede cifrar atributos mediante FHE usando la clave pública del DP, la cual se encuentra accesible en DB. También puede publicar los ciphertexts en IPFS e insertar los CIDs correspondientes como atributos en las VCs emitidas.
R3	Sí	El DP puede generar el CC y las claves Threshold FHE, registrar la información pública en el DB para que esté accesible, y notificar el registro a través del Holder.
R4	Sí	El DP puede almacenar las VCs en la wallet y generar presentaciones SSI a partir de ellas, seleccionando únicamente los atributos solicitados por el DC.
R5	Sí	El DP puede recuperar los atributos cifrados desde IPFS mediante los CIDs, realizar descifrados parciales y fusionar los resultados para verificar la información asociada a través del Holder.
R6	Sí	El DC puede solicitar presentaciones de atributos específicos al DP y procesar las respuestas correspondientes a través del Verifier.
R7	Sí	El DC puede recuperar los atributos cifrados desde IPFS empleando los CIDs incluidos en la presentación SSI recibida.
R8	Sí	El DC puede cifrar los valores de verificación y ejecutar operaciones homomórficas para realizar comparaciones privadas sobre los atributos cifrados.
R9	Sí	El DC puede realizar un descifrado parcial utilizando la clave privada expuesta por el DP, y fusionar los fragmentos obtenidos para recuperar el resultado final en claro.

VI. CONCLUSIONES

En este trabajo se ha demostrado la viabilidad de integrar técnicas de cifrado FHE y Threshold FHE dentro de un ecosistema SSI habilitando procesos de caracterización de datos que preserven la privacidad de los atributos sensibles. La implementación realizada confirma que es posible extender las capacidades tradicionales de las VCs para incluir atributos cifrados, sobre los que se pueden ejecutar comparaciones privadas sin revelar su contenido en ningún momento del proceso.

El prototipo desarrollado muestra que la combinación de SSI y FHE constituye un enfoque sólido para gestionar atributos sensibles, en escenarios donde intervienen múltiples

actores con diferentes niveles de confianza. En particular, el uso de descifrado bilateral mediante Threshold FHE garantiza la integridad del proceso de comparación, y evita manipulaciones por parte de los participantes. Los tiempos obtenidos en las pruebas experimentales, especialmente en las etapas de cifrado y descifrado, resultan compatibles con aplicaciones reales, aun cuando la fase de comparación y búsqueda conlleva un coste computacional más elevado debido a la cantidad y la naturaleza de las operaciones homomórficas.

Los resultados obtenidos evidencian que la propuesta satisface todos los requisitos funcionales definidos, permitiendo la emisión, custodia y verificación de atributos cifrados de manera interoperable con estándares SSI existentes. El enfoque presentado se posiciona como una contribución relevante para el desarrollo de arquitecturas de datos donde la confidencialidad, la verificabilidad y la soberanía de los participantes resultan elementos fundamentales. Finalmente, este trabajo abre la puerta a futuras líneas de investigación orientadas a mejorar la eficiencia de las operaciones homomórficas, ampliar la variedad de comparación soportadas y explorar su aplicabilidad en entornos con mayores exigencias de escalabilidad.

Finalmente, como línea de trabajo futuro, se plantea la definición explícita de un modelo de amenazas y la realización de un análisis de seguridad más formal, incluyendo razonamientos o pruebas criptográficas que permitan caracterizar de manera rigurosa las garantías de seguridad proporcionadas por la combinación de SSI, FHE y Threshold FHE propuesta.

AGRADECIMIENTOS

Esta iniciativa de investigación cuenta con el apoyo del Programa Marco Horizonte Europa de la Unión Europea para la Investigación y la Innovación, en el marco del proyecto TRUSTEE (Acuerdo de Subvención nº 101070214).

REFERENCIAS

- [1] N. V. Kulabukhova, “Zero-Knowledge Proof in Self-Sovereign Identity,” vol. 2507, 2019, pp. 381–385.
- [2] I. Seco-Aguirre, C. Regueiro, E. Jacob, and et al., “Extending Self-Sovereign Identity Using Fully Homomorphic Encryption to Enhance the Privacy of Verifiable Credentials,” Rochester, NY, Jun. 2025. [Online]. Available: <https://papers.ssrn.com/abstract=5292633>
- [3] X. Yi, R. Paulet, and E. Bertino, “Homomorphic Encryption,” in *Homomorphic Encryption and Applications*. Cham: Springer International Publishing, 2014, pp. 27–46. [Online]. Available: https://doi.org/10.1007/978-3-319-12229-8_2
- [4] C. Moore, M. O’Neill, E. O’Sullivan, and et al., “Practical homomorphic encryption: A survey,” in *ISCAS conference*, Jun. 2014, pp. 2792–2795, iSSN: 2158-1525. [Online]. Available: <https://ieeexplore.ieee.org/document/6865753/>
- [5] A. Jain, P. M. R. Rasmussen, and A. Sahai, “Threshold Fully Homomorphic Encryption,” 2017, publication info: Preprint. MINOR revision. [Online]. Available: <https://eprint.iacr.org/2017/257>
- [6] G. Asharov, A. Jain, A. López-Alt, and et al., “Multiparty Computation with Low Communication, Computation and Interaction via Threshold FHE,” in *Advances in Cryptology – EUROCRYPT 2012*. Springer, Berlin, Heidelberg, 2012, pp. 483–501, iSSN: 1611-3349. [Online]. Available: https://link.springer.com/chapter/10.1007/978-3-642-29011-4_29
- [7] A. Al Badawi, J. Bates, F. Bergamaschi, and et al., “OpenFHE: Open-Source Fully Homomorphic Encryption Library,” in *Proceedings of the 10th Workshop on Encrypted Computing & Applied Homomorphic Cryptography*. Los Angeles CA USA: ACM, Nov. 2022, pp. 53–63. [Online]. Available: <https://dl.acm.org/doi/10.1145/3560827.3563379>
- [8] A. Feer, “Privacy Preserving String Search using Homomorphic Encryption,” Ph.D. dissertation, Swiss Federal Institute of Technology Zurich, 2024.
- [9] Zama, “Encrypted search using fully homomorphic encryption,” 2022. [Online]. Available: <https://www.zama.ai/post/encrypted-search-using-fully-homomorphic-encryption>
- [10] S. Halevi and V. Shoup, “HElib - Country Lookup Example,” 2021. [Online]. Available: https://github.com/homenc/HElib/tree/master/examples/BGV_country_db_lookup
- [11] E. Morais, C. Van Wijk, and T. Koens, “Zero Knowledge Set Membership,” *SN Applied Sciences*, vol. 1, no. 8, p. 946, 2018. [Online]. Available: <http://link.springer.com/10.1007/s42452-019-0989-z>
- [12] A. Preukschat and D. Reed, *Self-Sovereign Identity*. Manning Publications, Aug. 2021, google-Books-ID: BfQ1EAAQBAJ.
- [13] G. Fedrecheski, J. M. Rabaey, L. C. P. Costa, and et al., “Self-Sovereign Identity for IoT environments: A Perspective,” in *2020 Global Internet of Things Summit (GloTS)*, Jun. 2020, pp. 1–6, arXiv:2003.05106 [cs]. [Online]. Available: <http://arxiv.org/abs/2003.05106>
- [14] I. Barclay, S. Radha, A. Preece, and et al., “Certifying Provenance of Scientific Datasets with Self-sovereign Identity and Verifiable Credentials,” Apr. 2020, arXiv:2004.02796 [cs]. [Online]. Available: <http://arxiv.org/abs/2004.02796>
- [15] Y. Bai, H. Lei, S. Li, and et al., “Decentralized and Self-Sovereign Identity in the Era of Blockchain: A Survey,” in *2022 IEEE International Conference on Blockchain*, Aug. 2022, pp. 500–507. [Online]. Available: <https://ieeexplore.ieee.org/document/9881610/>
- [16] M. Alizadeh, K. Andersson, and O. Schelén, “Performance Analysis of Verifiable Data Registry Solutions for Decentralized Identifiers,” in *2022 IEEE Asia-Pacific Conference on Computer Science and Data Engineering (CSDE)*, Dec. 2022, pp. 1–8. [Online]. Available: <https://ieeexplore.ieee.org/document/10089278/>
- [17] “bcgov/von-network,” Jan. 2026, original-date: 2017-11-07T19:00:37Z. [Online]. Available: <https://github.com/bcgov/von-network>
- [18] H. Foundation, “Hyperledger Aries.” [Online]. Available: <https://www.hyperledger.org/projects/aries>
- [19] A. Siqueira, A. F. Da Conceição, and V. Rocha, “Performance Evaluation of Self-Sovereign Identity Use Cases,” in *DAPPS conference*, Jul. 2023, pp. 135–144, iSSN: 2835-3498. [Online]. Available: <https://ieeexplore.ieee.org/document/10237035/>

How AI Agents Construct Privacy-Preserving Bitcoin Transactions

Jaume Costa-Calvoparra

Universitat Autònoma de Barcelona
Dept. Information and Communications Engineering
jaume.costa@autonoma.cat

Jordi Herrera-Joancomartí

Universitat Autònoma de Barcelona
Dept. Information and Communications Engineering
jordi.herrera@uab.cat

Abstract—We investigate whether AI agents, equipped with large language models (LLMs) and Bitcoin-specific tools, can construct privacy-preserving Bitcoin transactions. Unlike existing AI-cryptocurrency systems where agents hold private keys, we propose a security model based on extended public keys (xpub) and Partially Signed Bitcoin Transactions (BIP-174 PSBTs), ensuring that agents can construct but never sign transactions. We develop an offline privacy scorer with 9 heuristics grounded in an adversary model and conduct a systematic evaluation of 10 LLM models across 5 prompting strategies, generating 142 PSBTs. Our results show that explicit privacy-oriented prompting yields measurable improvements over naive baselines, with the best model achieving a fee-filtered privacy score of 83.33 out of 100. However, we identify a fundamental trade-off: 15.5% of generated PSBTs exhibit astronomical fee rates, and fee errors correlate strongly with prompt complexity. Current AI agents demonstrate conceptual understanding of Bitcoin privacy but lack the operational reliability required for real-world deployment.

Index Terms—Bitcoin, Privacy, AI Agents, PSBT, Large Language Models, Transaction Analysis

Type of contribution: *Original research (8-page limit)*

I. INTRODUCTION

Bitcoin remains the most widely adopted cryptocurrency, with a market capitalization exceeding one trillion dollars and millions of daily transactions processed on its network [1]. While often perceived as anonymous, Bitcoin operates under a pseudonymous model: every transaction is recorded on a public, append-only ledger visible to any observer. Addresses serve as pseudonyms, but they provide no inherent guarantee of unlinkability. Once a single address is associated with a real-world identity, through an exchange, or a payment, the entire transaction history linked to that address becomes attributable [2].

The privacy properties of a Bitcoin transaction depend critically on *how* the transaction is constructed. Decisions such as which unspent transaction outputs (UTXOs) to consume as inputs, how many outputs to create, what values to assign them, and how fees are handled all leave structural fingerprints that sophisticated observers can exploit. A poorly constructed transaction can reveal the sender's total balance, identify the change output, and link otherwise unrelated addresses. Conversely, a carefully crafted transaction can make such analysis significantly more difficult. This observation motivates a fundamental question: can the construction of Bitcoin transactions be automated in a way that preserves user privacy?

The structural analysis of Bitcoin transactions has been extensively studied over the past decade. Meiklejohn et al. [3]

introduced the Common Input Ownership Heuristic (CIOH), which posits that all inputs consumed in a single transaction are controlled by the same entity. This deceptively simple heuristic proved remarkably effective for clustering addresses into identity groups. Ron and Shamir [4] applied graph analysis techniques to the Bitcoin transaction graph and demonstrated that large-scale de-anonymization was feasible even with limited external information. Androulaki et al. [5] conducted a simulation-based study showing that user behavior patterns in Bitcoin are highly susceptible to profiling and linkage attacks, even in the absence of direct identity leaks.

Complementing input clustering, change address detection provides a second powerful analytical axis. When a user spends a UTXO whose value exceeds the payment amount, the wallet creates a *change output* returning the surplus to the sender. Möser and Narayanan [6] formalized several heuristics for identifying change outputs, including value-based analysis, address type matching, and round-number detection. Together, CIOH and change detection allow passive observers to construct detailed maps of fund flows, effectively stripping away the pseudonymous veil that Bitcoin ostensibly provides.

Several privacy-enhancing techniques have been proposed to counteract these analytical methods. CoinJoin, introduced by Maxwell [7], allows multiple users to collaboratively construct a single transaction that combines their inputs and outputs, thereby breaking the CIOH assumption. PayJoin (BIP-78) takes a different approach: the payment receiver contributes inputs to the transaction, making it indistinguishable from a regular payment and defeating common heuristics. Wallet-level coin selection algorithms have also been studied as a defense mechanism; Stutz et al. [8] analyzed how different selection strategies affect privacy, while Schnoering et al. [9] proposed optimized approaches that minimize information leakage. Recent work by Gavenda et al. [10] has further analyzed input-output mappings in CoinJoin transactions with arbitrary values, demonstrating the analytical challenges that non-equal-output schemes introduce. However, all of these privacy-enhancing techniques require either active user participation, coordination between multiple parties, or the use of specialized wallet software, barriers that limit their practical adoption.

In parallel, a recent and rapidly growing trend is the deployment of AI agents that autonomously manage cryptocurrency wallets and execute on-chain transactions. Such systems, like ElizaOS by Walters et al. [11], exemplify Web3-native frameworks where agents hold private keys and can

sign and broadcast transactions without human oversight. This approach is shared by many trading bots and DeFi portfolio managers but introduces catastrophic risks (e.g., prompt-injection key exfiltration, unauthorized transfers, and loss of user sovereignty). At the same time, recent progress in tool-augmented LLM agents—such as ReAct [12], which interleaves reasoning with tool use, and orchestration frameworks like LangGraph [13]—makes it plausible to design agents that can perform multi-step wallet tasks. However, prior work has not studied agents operating with only public key material, nor evaluated whether such agents can construct structurally privacy-preserving transactions in the UTXO model, where privacy depends on subtle transaction-structure and fingerprinting considerations.

The contributions of this paper are as follows:

- We introduce a security model for AI-assisted Bitcoin wallets where the agent only holds a xpub and produces *unsigned* PSBTs (BIP-174 [14]) and signing has to be performed by a human.
- We implement TxPrivScore, an offline Bitcoin transaction privacy scorer based on 9 heuristics derived from an explicit adversary model.
- We run a systematic evaluation of 10 LLMs (6 closed-source, 4 open-source) under 5 prompting strategies.
- We observe a recurring trade-off between privacy and fee correctness. Stronger prompting tends to improve privacy scores but increases fee mistakes, including 15.5% cases with astronomical fees.

The rest of the paper is organized as follows: Section II discusses the security models for AI agents interacting with Bitcoin wallets. In Section III, we present our agent architecture and the TxPrivScore system. Section IV details our experimental evaluation and results. Finally, Section V concludes the paper and outlines future directions.

II. BACKGROUND

A. The Current Landscape: Agents with Private Keys

The integration of large language models (LLMs) with cryptocurrency wallets has produced a new class of autonomous financial agents. Frameworks such as ElizaOS [11] enable AI agents to hold private keys, sign transactions, and broadcast them to the Bitcoin network without human intervention. Similar architectures also appear in adjacent ecosystems: for example, open-source trading bot stacks such as Hummingbot include wallet management and on-chain execution primitives (e.g., swaps and liquidity management) [18], [19], while DeFi management platforms expose always-on automation bots that monitor positions and automatically execute strategy adjustments once configured thresholds are reached [20], [21]. More generally, DeFi automation networks provide “decentralized cloud functions” that can trigger on-chain transactions for tasks such as yield farming, swaps, and liquidity management [22], [23]. In each case, the autonomous component ultimately requires transaction authorization (directly via a private key or via delegated execution privileges), concentrating spending power into an automated control plane.

This design introduces a threat surface that is fundamentally orthogonal with decades of security engineering in

the cryptocurrency ecosystem. Prompt injection attacks can manipulate an agent into transferring funds to an attacker-controlled address. Model hallucinations may cause the agent to send incorrect amounts or to misparse destination addresses. Furthermore, private keys must be accessible to the inference pipeline, creating exposure through LLM provider infrastructure, API key compromise, or memory leaks in the serving stack. Crucially, once a signed transaction is broadcast and confirmed, it is irreversible, there is no recourse mechanism on the Bitcoin base layer.

The Bitcoin community has invested considerable effort in reducing the scope of signing capability. Hardware wallets isolate keys in tamper-resistant enclaves. Multi-signature schemes (e.g., 2-of-3) require multiple independent parties to authorize a transaction. Timelocks and vaults add temporal constraints to spending. AI agents that hold raw private keys effectively bypass all of these safeguards, concentrating signing power in a software component that is, by design, susceptible to adversarial inputs and stochastic behavior.

B. Our Approach: Extended Public Key Only

We propose an architecture in which the AI agent never possesses signing keys. Instead, the agent receives an extended public key (xpub) as defined in BIP-32 [15]. From the xpub, the agent can derive fresh receiving addresses, enumerate unspent transaction outputs (UTXOs), query wallet balances, and monitor fee-rate conditions, all without any ability to spend funds. When a transaction is needed, the agent constructs a Partially Signed Bitcoin Transaction (PSBT) following the BIP-174 specification [14]. The PSBT encodes all transaction inputs, outputs, and relevant metadata in a standardized unsigned format. The PSBT is then reviewed and authorized by a human operator, and signed by an external signing component such as a hardware wallet or a hardware security module (HSM). After signatures are applied, the finalized transaction is broadcast to the network.

This separation yields three key security properties. First, *no fund exfiltration*: the fact that the agent cannot sign implies that a compromised agent cannot move funds regardless of the severity of the exploit. Second, *auditability*: every PSBT constitutes a complete, inspectable proposal that can be verified before any commitment is made. Third, *separation of concerns*: transaction construction is delegated to the AI agent, while transaction authorization remains with the human or HSM, preserving the trust boundaries that the Bitcoin security ecosystem has established.

This architecture is particularly well-suited for privacy-enhancing transaction construction. Privacy on Bitcoin is determined almost entirely at the time a transaction is *constructed*, not when it is signed. The selection of which UTXOs to spend, the number and denomination of outputs, the ordering of inputs and outputs, the fee rate, and the use of change addresses are all choices embedded in the unsigned transaction. An AI agent operating under our model retains full autonomy over these construction-time decisions while the human signer need only verify the high-level intent, the destination and amount, without understanding the underlying privacy logic. As illustrated in Fig. 1, this contrasts sharply with existing approaches in which the agent both constructs and signs, conflating optimization with authorization.




Figure 1. Two agent architectures compared. Model A (existing): the agent holds a private key and broadcasts signed transactions autonomously. Model B (ours): the agent constructs an unsigned PSBT from an extended public key; a human operator reviews and authorizes it, and an external signing component (hardware wallet or HSM) applies signatures before the finalized transaction is broadcast.

III. SYSTEM DESIGN

This section presents the two core components of our system: an LLM-powered agent capable of constructing Bitcoin transactions with privacy-aware strategies, and TxPrivScore, an offline heuristic-based scorer that evaluates the privacy properties of the resulting transactions.

A. Agent Architecture

The Bitcoin AI agent is built on the LangGraph framework [13], implementing a ReAct-style [12] state graph with dedicated tool nodes. The architecture supports multiple LLM providers, including Anthropic, OpenAI, Google, and OpenRouter APIs, allowing the system to leverage different models depending on availability, cost, or capability requirements. A critical security invariant governs the agent’s design: it operates exclusively with an extended public key (xpub) and never handles private keys. The agent can derive addresses, inspect wallet state, and construct unsigned transactions, but all signing occurs externally, preserving a strict separation between transaction construction and key management.

The agent is equipped with seven tools that collectively provide full control over transaction construction [16]:

- 1) **get_balance**: queries the wallet balance derived from the xpub, providing the agent with an up-to-date view of available funds.
- 2) **generate_address**: derives new receiving addresses following the BIP-84 standard (P2WPKH native SegWit), ensuring address freshness.
- 3) **list_utxos**: enumerates unspent transaction outputs available for spending, including their values, script types, and confirmation status.
- 4) **get_fee_rates**: retrieves current network fee rate estimates at multiple confirmation targets, enabling informed fee selection.
- 5) **create_transaction_manual**: constructs a Partially Signed Bitcoin Transaction (PSBT) with full manual control over inputs, outputs, and amounts.
- 6) **decode_psbt**: decodes and verifies a generated PSBT, allowing the agent to inspect the transaction structure before finalization.
- 7) **verify_utxo**: verifies whether a transaction exists on-chain and returns its outputs along with their spend status.

These tools are implemented as standalone Python modules within our prototype [16]. Blockchain state queries such as wallet balances, UTXO sets, and address history are served by a local Bitcoin Core node accessed via its JSON-RPC interface [24], avoiding dependence on third-party

blockchain explorers during the experiments. PSBT construction and decoding follow custom implementations of the BIP-174 specification [14] without relying on external Bitcoin transaction libraries; address derivation uses the `hdwallet` library [27] for BIP-32/84 key derivation [15], [26] from the extended public key. Fee rate estimates are obtained from the Mempool.space public API [28], because Bitcoin Core’s `estimatesmartfee` RPC returns an estimate for one confirmation target per call rather than a multi-target response in the same format [25].

Through these tools, the agent exercises fine-grained control over every dimension of PSBT construction that affects privacy: input selection (which UTXOs to spend and how many to include), output design (amounts, destination addresses, and the number of outputs), fee rate selection, and output ordering. The agent may also introduce decoy outputs, split amounts across multiple outputs, or consolidate multiple UTXOs to create mixing-like structures, all guided by the privacy objective specified in the user’s request.

The agent follows a conversational loop: it receives a user request describing the desired transaction, reasons about the task by analyzing available UTXOs and current fee conditions, iteratively calls tools as needed, and produces a final PSBT encoded in BIP-174 format [14]. The PSBT can then be exported for external signing by a hardware wallet or other signing device.

B. The TxPrivScore

The TxPrivScore (privacy scorer) constitutes the analytical backbone of our system, providing quantitative privacy assessments of Bitcoin transactions based purely on their structural properties.

1) *Design Principles*: Four principles govern the scorer. First, it is **fully offline**: no network calls are made during scoring, and all analysis is performed on the PSBT structure alone. This ensures reproducibility and eliminates dependency on external services. Second, we assume a **passive on-chain adversary** with access to the public blockchain and the ability to apply widely used transaction-structure heuristics for address clustering and change detection (e.g., CIOH and graph-based linkage), as commonly considered in prior Bitcoin privacy analyses. Third, it enforces a **no false confidence** policy: missing or incomplete data (e.g., unresolvable input scripts) degrades the confidence level of the assessment rather than being silently ignored. Fourth, it prioritizes **explainability**: every finding includes a severity level, a human-readable reason, and a suggested mitigation strategy.

2) *Scoring Methodology*: The scoring system assigns a base score of 100, representing perfect privacy. Each heuristic evaluation applies penalties (negative impact for privacy violations) or bonuses (positive impact for privacy-enhancing patterns). The final score is clamped to the range $[0, 100]$ and mapped to a letter grade: A+ (≥ 90), A (≥ 80), B (≥ 65), C (≥ 50), D (≥ 30), and F (< 30).

The overall score is decomposed into three sub-scores corresponding to distinct privacy threat categories: *Clustering* (resistance to input-ownership and graph-based linking), *Change Detection* (resistance to identifying the change output), *Fingerprinting* (resistance to wallet and software identification).

Table I
 PRIVACY HEURISTICS EVALUATED BY THE SCORER. EACH HEURISTIC TARGETS A SPECIFIC PRIVACY THREAT CATEGORY AND CONTRIBUTES PENALTIES OR BONUSES TO THE OVERALL SCORE.

#	Heuristic	Category	Description
H1	Script Homogeneity	Fingerprinting	Checks if all inputs and outputs use the same script type (e.g., P2WPKH)
H2	Dust Detection	Clustering	Identifies outputs below the dust threshold (e.g., 294 sat for P2WPKH)
H3	CIOH Clustering	Clustering	Evaluates common-input-ownership inference from multiple inputs [3]
H4	Round Amt. Asymmetry	Change Det.	Round payment amounts reveal which output is likely change [6]
H5	Fee Rate Fingerprint	Fingerprinting	Unusual fee rates can identify specific wallet software
H6	BIP-69 Ordering	Fingerprinting	Lexicographic ordering [17] reveals BIP-69 compliance
H7	Change Output Det.	Change Det.	Multi-signal analysis combining decimal precision and amount patterns
H8	Equal Output	Clustering	Detects equal-output patterns indicating CoinJoin-like [7] structures
H9	Address Reuse	Clustering	Detects reused addresses, which completely destroy privacy

Each sub-score aggregates the penalties and bonuses from its constituent heuristics. Additionally, a *confidence level*, HIGH, MEDIUM, or LOW, is reported based on data completeness and signal availability to help users interpret how strongly the scorer can support its conclusions in each category (e.g., whether clustering signals are clearly observable, or whether the change output can be identified with high certainty). In practice, HIGH indicates that the relevant evidence is sufficiently observable, and the assessment is robust, whereas LOW indicates that missing fields or ambiguous structure prevent reliable inference (for example, the scorer cannot meaningfully determine which output is change), so the corresponding sub-score should be treated as less conclusive.

3) *Privacy Heuristics*: The scorer evaluates nine heuristics spanning the three privacy categories. Table I summarizes each heuristic, its category, and its analytical focus.

Heuristic H1 (Script Type Homogeneity) penalizes transactions where inputs and outputs use heterogeneous script types, as this creates a fingerprintable pattern that aids clustering. H2 (Dust Output Detection) flags outputs below protocol-defined dust thresholds, which are often used as tracking vectors. H3 (Common Input Ownership Heuristic) evaluates the well-known assumption that all inputs to a transaction belong to the same entity, transactions with fewer inputs receive lower penalties. H4 (Round Amount Asymmetry) identifies round-number outputs that typically correspond to payments, thereby revealing which remaining output is change. H5 and H6 target wallet fingerprinting through fee rate analysis and BIP-69 lexicographic ordering compliance [17], respectively. H7 performs multi-signal change detection by combining decimal precision analysis with amount pattern recognition. H8 rewards equal-output structures that resemble CoinJoin transactions, as these provide plausible deniability about payment direction. Finally, H9 detects address reuse in the transaction itself, which is widely recognized as the single strongest deanonymization signal in Bitcoin analytics.

4) *Fee Sanity Check*: The scorer includes a fee sanity check as a separate, orthogonal dimension from privacy scoring. This check operates as a binary flag, *sane* or *insane*, and does not influence the privacy score. The rationale for this separation is straightforward: a PSBT may achieve an excellent privacy score (e.g., 91/100) while simultaneously specifying an absurd fee rate (e.g., 3,000,000 sat/vB), which would result in catastrophic financial loss upon broadcast. Conversely, a transaction with a perfectly reasonable fee may exhibit poor privacy properties. Privacy and operational correctness are

orthogonal concerns, and conflating them into a single metric would obscure actionable information. The fee sanity flag is therefore reported alongside the privacy score, ensuring that users and downstream systems can independently assess both dimensions before authorizing a transaction for signing.

IV. EXPERIMENTAL EVALUATION

This section presents the experimental design, methodology, and results of our evaluation of ten large language models acting as Bitcoin transaction agents. We assess their ability to construct privacy-preserving Partially Signed Bitcoin Transactions (PSBTs) under varying prompt strategies, and we identify a critical trade-off between privacy improvement and transaction fee sanity.

A. Experiment Design

We design a controlled experiment matrix comprising 10 models, 5 prompt strategies, and 3 repetitions per combination, yielding 150 planned experiments. Of these, 142 produced valid PSBTs that could be parsed and scored by TxPrivScore; the remaining 8 corresponded to model/prompt combinations where the agent failed to produce a structurally valid PSBT. All experiments were conducted under identical conditions: temperature was set to 1.0 (i.e., the agent’s generation parameter controlling output randomness and diversity) to encourage output diversity, each interaction had a 300-second timeout, and the agent operated in an xpub-only mainnet-derived environment without signing capabilities.

1) *Models Under Test*: Table II enumerates the ten models evaluated, spanning both closed-source frontier models and open-source alternatives accessed via OpenRouter. The open-source models were not the most powerful available; instead, we selected models that are feasible to run on commodity hardware (e.g., a machine with 128 GB of RAM). This selection covers the major model families currently available and enables a comparison between proprietary and open-weight architectures on a specialized financial task.

2) *Prompt Strategies*: We employ five prompt strategies of increasing specificity and privacy awareness, designed to probe whether and how explicit privacy guidance affects transaction construction:

- 1) **Basic**. The agent receives only a functional request: “Make me a PSBT of 3 BTC to one of my addresses.” This serves as the baseline with no privacy guidance whatsoever, measuring only the agent’s default transaction construction behavior.

Table II
MODELS EVALUATED IN THE EXPERIMENTAL STUDY.

Category	Model	Provider
Closed-source	Claude Opus 4.5	Anthropic
Closed-source	Claude Opus 4.6	Anthropic
Closed-source	Claude Sonnet 4.5	Anthropic
Closed-source	GPT-5.2	OpenAI
Closed-source	GPT-5.2 Pro	OpenAI
Closed-source	Gemini 3 Pro	Google
Open-source	DeepSeek V3.2	OpenRouter
Open-source	Llama 3.3 70B	OpenRouter
Open-source	Mistral Large	OpenRouter
Open-source	Qwen 2.5 72B	OpenRouter

- 2) **Privacy Simple.** The same functional request is augmented with a minimal privacy cue: the phrase “*as private as possible*” is appended. This tests whether a lightweight, non-technical hint is sufficient to trigger privacy-enhancing behavior.
- 3) **Multi-turn Simple.** The agent first receives the basic prompt and produces a transaction. A follow-up message then requests: “*Now make it more private.*” This evaluates the agent’s capacity for iterative refinement and whether a second pass yields measurable improvement.
- 4) **Multi-turn Detailed.** Identical to Multi-turn Simple in its first turn, but the follow-up provides explicit technical guidance requesting the use of multiple UTXOs as inputs, inclusion of decoy outputs, and amount obfuscation techniques. This tests whether detailed technical instructions enable the agent to construct substantially more private transactions.
- 5) **Privacy Detailed.** A single comprehensive prompt that combines the functional request with full privacy instructions in one message. This strategy tests whether the agent can process and act upon complex, multi-faceted privacy requirements without iterative guidance.

Strategies 1 through 5 thus form a gradient from no privacy awareness to maximal explicit instruction, enabling us to isolate the marginal contribution of prompt specificity to transaction privacy.

B. Results

We organize our findings around five key observations that emerged from the 142 scored PSBTs.

1) *Finding 1: Baseline Privacy Is Accidental:* With basic prompts, the vast majority of models produce transactions that score exactly 80 out of 100 on TxPrivScore. These transactions are structurally minimal, typically comprising a single input and two outputs (the payment and a change output), and are nearly identical across all ten models. The 80-point score arises not from intentional privacy engineering but from two incidental properties: consistent use of Pay-to-Witness-Public-Key-Hash (P2WPKH) address types, which reduces script-type fingerprinting, and structurally simple one-input/two-output transactions, which avoid multi-input clustering penalties. Critically, change detection remains straightforward: the `change_detection` sub-score averages 85, indicating that a chain-analysis heuristic can reliably identify the change output due to predictable output ordering and amount patterns. We characterize this baseline as *accidental privacy*; the score




Figure 2. Average privacy score by prompt strategy across all models. More detailed prompts improve scores but increase variance.

reflects adherence to modern Bitcoin defaults rather than any deliberate privacy strategy by the agent.

2) *Finding 2: Prompting Measurably Improves Privacy:* Explicit privacy-oriented prompting produces statistically meaningful improvements over the baseline, though the gains are modest and accompanied by increased variance. Fig. 2 illustrates the average privacy score by prompt strategy across all models. The most notable result is GPT-5.2 with the multi-turn detailed strategy, which achieves a mean fee-filtered score of 83.33, the highest reliable score observed in our experiments. At the individual transaction level, Claude Opus 4.6 with multi-turn detailed prompting reaches a maximum score of 91 among fee-sane PSBTs, demonstrating that current models can, in principle, construct transactions with substantially enhanced privacy. Part of why these improvements appear modest is an asymmetry in the scoring space: once transactions sit around the 80-point region, there is less “headroom” to gain than below 80, so experimentation with new privacy techniques is more likely to trigger additional penalties (lowering the score) than to unlock the relatively rarer bonuses needed to push scores upward.

The average improvement from basic to the best-performing prompt strategy ranges from approximately 3 to 10 points depending on the model. However, a critical caveat accompanies these gains: variance increases dramatically with prompt complexity. Under basic prompts, standard deviation across repetitions is typically zero (all three repetitions produce identical transactions). Under multi-turn detailed and privacy detailed strategies, standard deviation rises to 18 or higher, indicating that the models’ privacy-enhancing behavior is inconsistent and non-deterministic. The same model and prompt combination may yield a high-privacy transaction in one run and a structurally flawed one in the next.

3) *Finding 3: The Fee Sanity Problem:* Perhaps the most consequential finding of this study concerns transaction fee rates. Of the 142 valid PSBTs, 22 (15.5%) exhibit astronomical fee rates, in extreme cases exceeding 15.6 million sat/vB, orders of magnitude above any plausible fee market condition. A PSBT that scores 92 on our privacy metric but specifies a fee rate of 11 million sat/vB is operationally useless: broadcasting such a transaction would destroy the vast majority of the transacted value in miner fees.

Fee insanity correlates strongly with prompt complexity.




Figure 3. Fee insanity rate by model and prompt strategy. Darker cells indicate higher rates of astronomical fee errors. Open-source models and complex prompts show the highest fee insanity.

Under basic prompts, most models produce transactions with reasonable fee rates, 0% fee insanity across all Anthropic models and most others. As prompts demand more sophisticated transaction structures, fee calculation errors proliferate. Under the privacy detailed strategy, DeepSeek V3.2 produces fee-insane transactions in 100% of cases (all 3 PSBTs), and Qwen 2.5 72B similarly exhibits 100% fee insanity (both valid PSBTs). By contrast, GPT-5.2 maintains an overall fee insanity rate of only 6.7% (1 out of 15 PSBTs), and all Anthropic models achieve 0% fee insanity under basic and privacy simple strategies. A concrete failure mode explains many of the extreme outliers among open-weight models: several repeatedly converged on a “best possible” structure of one input and one output, which is technically appealing because it eliminates change and minimizes linkage, and would indeed score near-perfectly if amounts were consistent. However, in our test wallet the smallest available UTXO was 10 BTC; when a model attempted to pay a smaller amount with no change output, the entire remainder was implicitly assigned to fees (e.g., on the order of 7 BTC), yielding an astronomically high effective sat/vB and rendering the transaction unusable despite being structurally valid. We observe this pattern predominantly in open-weight models, and hypothesize that stronger reasoning-oriented closed models tend to explicitly consider and reject “no-change” constructions when the implied fee becomes implausible.

Fig. 3 visualizes this phenomenon as a heatmap of fee insanity rates across models and prompt strategies. The pattern is unambiguous: the bottom-right region (open-source models with complex prompts) concentrates the highest failure rates, while the top-left region (closed-source models with simple prompts) remains largely clean. This finding has direct implications for the deployment of AI agents in financial applications, where a single fee miscalculation can result in irreversible loss of funds.

4) *Finding 4: Model Comparison:* To fairly evaluate each model’s demonstrated privacy capability, we report the *Best-3* score: the average of the three highest-scoring fee-sane PSBTs per model, regardless of prompt strategy. This metric captures what each model can achieve at its best while excluding oper-

Table III
MODEL PERFORMANCE SUMMARY. BEST-3 REPORTS THE AVERAGE PRIVACY SCORE OF THE THREE HIGHEST-SCORING FEE-SANE PSBTs PER MODEL, REGARDLESS OF PROMPT STRATEGY.

Model	Best-3	Success	Fee San.
Cl. Opus 4.6	88.00	100%	100%
GPT-5.2	85.67	100%	93.3%
Cl. Son. 4.5	85.33	100%	86.7%
DeepSeek V3.2	82.67	100%	66.7%
Cl. Opus 4.5	81.67	100%	93.3%
Gemini 3 Pro	81.67	100%	100%
GPT-5.2 Pro	80.00	93.3%	100%
Mistral Large	80.00	86.7%	69.2%
Qwen 2.5 72B	80.00	80.0%	58.3%
Llama 3.3 70B	79.33	86.7%	69.2%




Figure 4. Best-3 privacy score per model (average of top 3 fee-sane PSBTs). Black lines show the mean across all fee-sane PSBTs; the gap between bar height and mean reveals behavioral inconsistency.

ationally unusable transactions. Unlike the per-prompt average used in Finding 2, the Best-3 draws from whichever prompt runs produced the strongest individual results, providing a capability-oriented rather than strategy-oriented comparison. Table III ranks all ten models by Best-3 score, and Fig. 4 visualises the results alongside overall means.

Six models exceed the 80-point baseline. Claude Opus 4.6 leads at 88.00 (top three individual scores: 91, 88, 85), followed by GPT-5.2 (85.67), Claude Sonnet 4.5 (85.33), DeepSeek V3.2 (82.67), and Claude Opus 4.5 and Gemini 3 Pro (both 81.67). The remaining four models, GPT-5.2 Pro, Mistral Large, Qwen 2.5 72B, and Llama 3.3 70B, cluster at or below the 80.00 baseline, indicating that their fee-sane outputs rarely improve upon the default one-input-two-output template.

The gap between Best-3 and overall mean, visible in Fig. 4, reveals each model’s *behavioral inconsistency*. Claude Opus 4.6 exhibits the largest gap (88.00 Best-3 versus 76.7 mean across all fee-sane PSBTs): it produces the strongest individual transactions in the entire study yet also generates many poor ones, pulling the mean well below its peak capability. GPT-5.2 shows a narrower gap (85.67 versus 80.1), indicating more consistent performance across runs and prompt strategies.

An important observation is that closed-source models do *not* underperform due to fee errors; they achieve an aggregate fee sanity rate of 95.6%. Instead, when these models attempt creative privacy strategies such as adding multiple

inputs or decoy outputs, the structural changes sometimes backfire: multiple inputs trigger CIOH clustering penalties (the clustering sub-score drops from 100 to 91–93 in affected PSBTs), and certain output structures degrade change detection resistance. In other words, the models take structural risks that sometimes improve and sometimes worsen privacy, producing a wide score distribution rather than a uniformly elevated one.

5) *Finding 5: Two Barriers to Reliable Privacy*: Synthesizing the preceding findings, we identify two distinct barriers that prevent current AI agents from reliably producing privacy-preserving Bitcoin transactions. The first barrier, *behavioral inconsistency*, affects all models regardless of provenance. The gap between best-of-three and mean scores across every model demonstrates that privacy-enhancing strategies are fundamentally non-deterministic: the same model and prompt may produce a PSBT scoring 91 in one run and 56 in the next. Creative strategies such as using multiple UTXOs, adding decoy outputs, and obfuscating amounts can improve change detection and fingerprinting sub-scores, but they simultaneously degrade clustering resistance due to Common Input Ownership Heuristic (CIOH) inference, when an agent adds multiple inputs, the scorer penalizes this as evidence of common ownership, causing the clustering sub-score to drop from 100 to 91–93. Crucially, this inconsistency is *not* primarily driven by fee errors for closed-source models. Of the 22 fee-insane PSBTs across the entire experiment, only 4 originate from closed-source models (a 4.4% fee insanity rate). When closed-source models produce low-scoring transactions under complex prompts, it is because their structural modifications, intended to enhance privacy, instead create fingerprintable patterns or make change detection easier. The agents take creative structural risks that sometimes improve and sometimes worsen the overall privacy profile.

The second barrier, *fee calculation errors*, is an asymmetric problem that predominantly affects open-source models. Of the 22 fee-insane PSBTs, 18 (81.8%) originate from open-source models, yielding a fee insanity rate of approximately 34% for open-source versus 4.4% for closed-source. Under complex prompting strategies, DeepSeek V3.2 and Qwen 2.5 72B reach 100% fee insanity rates, rendering all of their privacy-enhanced PSBTs operationally useless regardless of structural quality. Fee insanity is thus the dominant barrier for open-source models but a minor concern for closed-source ones.

V. CONCLUSIONS AND FURTHER WORK

This paper analyzes whether AI agents, operating with only an extended public key and no signing authority, can construct privacy-preserving Bitcoin transactions. The answer is nuanced: they demonstrate genuine capability but not yet reliable execution. Using the Best-3 metric, the average of each model’s three highest-scoring fee-sane PSBTs, six of the ten evaluated models exceeded the 80-point accidental-privacy baseline. Claude Opus 4.6 led at 88.00 (individual top scores: 91, 88, 85), followed by GPT-5.2 (85.67) and Claude Sonnet 4.5 (85.33). When guided by explicit privacy instructions, agents successfully applied techniques such as multi-input consolidation, decoy outputs, and amount obfuscation. The xpub-only security model based on BIP-174 PSBTs proved

viable in our experimental setup, demonstrating that agents can construct structurally complex transactions without ever accessing private keys.

Two distinct barriers prevent reliable deployment. First, *behavioral inconsistency* affects all models: the gap between Best-3 and mean scores is substantial (e.g., Claude Opus 4.6: 88.0 vs. 76.7 mean), revealing that identical configurations produce both excellent and poor transactions. Creative strategies that improve change detection or fingerprinting sub-scores often degrade clustering resistance through CIOH inference, a structural tension inherent to the privacy heuristics. Second, *fee calculation errors* are an asymmetric problem: 18 of 22 fee-insane PSBTs (81.8%) originate from open-source models, yielding a 34% fee insanity rate versus 4.4% for closed-source. These barriers require different interventions.

Several concrete directions for future work emerge from these findings. To address behavioral inconsistency, a *scorer-in-the-loop* architecture could feed privacy evaluation results back to the agent within a single session, enabling iterative refinement until a satisfactory score is reached. Complementarily, *fine-tuning* on curated datasets of privacy-preserving transaction patterns could internalize best practices that currently require elaborate prompting, narrowing the gap between Best-3 and average-case performance. *Multi-agent verification*, where one agent constructs the transaction and another reviews its privacy properties before presenting the PSBT for signing, could combine creative exploration with systematic quality assurance. To address fee errors, *fee guardrails* integrated at the tool level (a simple bounds check before PSBT finalization) would eliminate fee insanity entirely, particularly benefiting open-source models. Finally, extending the evaluation to *online scoring* against the live blockchain and to more complex protocols such as *PayJoin* (BIP-78), where both sender and receiver contribute inputs, would test the generality of our findings.

ACKNOWLEDGEMENTS

This work is funded by the projects PID2021-125962OB-C33 SECURING/NET and PID2024-156914OB-C43 SAFE-BLOCKCHAIN, funded by the Ministerio de Ciencia e Innovación, la Agencia Estatal de Investigación and the European Regional Development Fund (ERDF); the DANGER Strategic Project of Cybersecurity C062/23, funded by the Spanish National Institute of Cybersecurity through the European Union - NextGenerationEU and the Recovery, Transformation and Resilience Plan.

REFERENCES

- [1] S. Nakamoto, “Bitcoin: A Peer-to-Peer Electronic Cash System,” 2008. [Online]. Available: <https://bitcoin.org/bitcoin.pdf>
- [2] M. Conti, S. Kumar E, C. Lal, and S. Ruj, “A Survey on Security and Privacy Issues of Bitcoin,” *IEEE Communications Surveys & Tutorials*, vol. 20, no. 4, pp. 3416–3452, 2018.
- [3] S. Meiklejohn, M. Pomarole, G. Jordan, K. Levchenko, D. McCoy, G. M. Voelker, and S. Savage, “A Fistful of Bitcoins: Characterizing Payments Among Men with No Names,” in *Proc. ACM Internet Measurement Conf. (IMC)*, pp. 127–140, 2013.
- [4] D. Ron and A. Shamir, “Quantitative Analysis of the Full Bitcoin Transaction Graph,” in *Proc. Financial Cryptography (FC)*, pp. 6–24, 2013.
- [5] E. Androulaki, G. O. Karame, M. Roeschlin, T. Scherer, and S. Capkun, “Evaluating User Privacy in Bitcoin,” in *Proc. Financial Cryptography (FC)*, pp. 34–51, 2013.

- [6] M. Möser and A. Narayanan, “Resurrecting Address Clustering in Bitcoin,” in *Proc. Financial Cryptography (FC)*, 2022.
- [7] G. Maxwell, “CoinJoin: Bitcoin Privacy for the Real World,” BitcoinTalk Forum, Aug. 2013.
- [8] R. Stütz, J. Stockinger, B. Haslhofer, P. Moreno-Sanchez, and M. Maffei, “Adoption and Actual Privacy of Decentralized CoinJoin Implementations in Bitcoin,” in *Proc. Workshop on Measurements, Attacks, and Defenses for the Web (MADWeb)*, 2022.
- [9] H. Schnoering and M. Vazirgiannis, “Heuristics for Detecting CoinJoin Transactions on the Bitcoin Blockchain,” *arXiv preprint arXiv:2311.12491*, 2023.
- [10] J. Gavenda, P. Svenda, S. Bobon, and V. Sedlacek, “Analysis of Input-Output Mappings in Coinjoin Transactions with Arbitrary Values,” *arXiv preprint arXiv:2510.17284*, 2025.
- [11] S. Walters, S. Gao, *et al.*, “Eliza: A Web3 Friendly AI Agent Operating System,” 2025. [Online]. Available: <https://github.com/elizaOS/eliza>
- [12] S. Yao, J. Zhao, D. Yu, N. Du, I. Shafran, K. Narasimhan, and Y. Cao, “ReAct: Synergizing Reasoning and Acting in Language Models,” in *Proc. ICLR*, 2023.
- [13] LangChain, “LangGraph: Build Stateful Multi-Actor Applications with LLMs,” 2024. [Online]. Available: <https://langchain-ai.github.io/langgraph/>
- [14] A. Chow, “BIP-174: Partially Signed Bitcoin Transaction Format,” Bitcoin Improvement Proposals, 2017. [Online]. Available: <https://github.com/bitcoin/bips/blob/master/bip-0174.mediawiki>
- [15] P. Wuille, “BIP-32: Hierarchical Deterministic Wallets,” Bitcoin Improvement Proposals, 2012. [Online]. Available: <https://github.com/bitcoin/bips/blob/master/bip-0032.mediawiki>
- [16] Jei23, “Bitcoin Agent Project,” 2026. [Online]. Available: <https://github.com/Jei23/bitcoin-agent-project>
- [17] D. Isler, “BIP-69: Lexicographical Indexing of Transaction Inputs and Outputs,” Bitcoin Improvement Proposals, 2015.
- [18] Hummingbot Foundation, “Gateway Commands,” Hummingbot Documentation. [Online]. Available: <https://hummingbot.org/gateway/commands/> (accessed: 2026-02).
- [19] Hummingbot Foundation, “FAQ,” Hummingbot Documentation. [Online]. Available: <https://hummingbot.org/faq/> (accessed: 2026-02).
- [20] DeFi Saver, “Automation,” DeFi Saver Help Center, Feb. 2026. [Online]. Available: <https://help.defisaver.com/features/automation>
- [21] DeFi Saver, “How does Automation work?,” DeFi Saver Help Center, Oct. 2025. [Online]. Available: <https://help.defisaver.com/features/automation/how-does-automation-work>
- [22] Gelato, “Unlock DeFi Automation with Gelato’s Web3 Functions,” Jun. 2023. [Online]. Available: <https://gelato.cloud/blog/defi-automation-gelato-web3-functions>
- [23] Gelato, “web3-functions-template,” GitHub repository. [Online]. Available: <https://github.com/gelatodigital/web3-functions-template> (accessed: 2026-02).
- [24] Bitcoin Core developers, “RPC API Reference,” Bitcoin Developer Documentation. [Online]. Available: <https://developer.bitcoin.org/reference/rpc/>
- [25] Bitcoin Core developers, “estimatesmartfee,” Bitcoin Developer Documentation. [Online]. Available: <https://developer.bitcoin.org/reference/rpc/estimatesmartfee.html>
- [26] P. Rusnak, “BIP-84: Derivation scheme for P2WPKH based accounts,” Bitcoin Improvement Proposals, 2017. [Online]. Available: <https://github.com/bitcoin/bips/blob/master/bip-0084.mediawiki>
- [27] M. T. Batu, “hdwallet,” Python Package Index (PyPI). [Online]. Available: <https://pypi.org/project/hdwallet/>
- [28] The Mempool Open Source Project, “REST API,” Mempool.space Documentation. [Online]. Available: <https://mempool.space/docs/api/rest>

Evaluating the Impact of a Cryptographically Relevant Quantum Computer on Bitcoin

Sergi Morales Duque

Departament d'Enginyeria de la
Informació i de les Comunicacions
Universitat Autònoma de Barcelona
Sergi.Morales@uab.cat

Julián Salas Piñón

Departament d'Enginyeria de la
Informació i de les Comunicacions
Universitat Autònoma de Barcelona
Julian.Salas@uab.cat

Jordi Herrera Joancomartí

Departament d'Enginyeria de la
Informació i de les Comunicacions
Universitat Autònoma de Barcelona
Jordi.Herrera@uab.cat

Abstract—Quantum computing threatens security on internet as we know it. Theoretically, quantum computers will be able to break the discrete logarithm problem (DLP) in a reasonable time due to their special capabilities. Bitcoin is one of eventually affected systems, mainly because it relies on public key cryptography to ensure many properties. We propose a new algorithm to measure and evaluate the impact of this technology on the protocol. Our results show the huge problem Bitcoin is facing, almost 25% of all coins generated are in risk of being stolen. Almost half of this vulnerable coins are locked behind addresses that exposed the public key, but the majority of them due to address reuse, which is also an issue for users privacy.

Index Terms—Bitcoin, quantum computing, public key, addresses, transaction, algorithm, bloom filter

Contribution type: *Original Research*

I. INTRODUCTION

Quantum computers are the next major breakthrough in the computing field. Thanks to their unique characteristics, they are capable of executing algorithms and solving problems much faster than current computers. This immense computing power marks a turning point, presenting a whole new horizon of challenges and opportunities. Many problems that were previously considered impossible mainly due to their complexity, are now solvable in a reasonable amount of time. One such challenge is the well-known Discrete Logarithm Problem (DLP), being the core of modern public key schemes. Therefore, theoretically, quantum computers will be able to compute a private key from a public one, threatening to break the cybersecurity we use nowadays.

A technology capable of breaking cryptography threatens every system that relies on cryptography, including Bitcoin. Quantum computers already exist and are usable, in some manner. However, in order to break the size of the actual public keys, a large number of *qubits*, the basic unit of these computers, are still necessary. So, it is not only a matter of developing a quantum computer, but it must be powerful enough to present a real problem. Quantum computers that possess the capability of such threat are known as Cryptographically Relevant Quantum Computers (CRQC). There is not a clear consensus on the time frame when a CRQC will be available, but most of experts do not expect to happen in the short or medium term.

The main objective of this work is to compute and evaluate the CRQC impact on Bitcoin, measuring the amount of funds that are vulnerable to a quantum computer attack. This will help the community to have a full picture of the impact and how urgent is to start thinking and working on a solution.

The paper will be organized as follows. In Section II, we present some background in order to understand the threat of CRQC in the Bitcoin protocol. Section III describes similar projects and their main drawbacks. In Section IV, we describe our system by explaining how we determine the vulnerable funds, how we optimize our system, and how is implemented. Section V shows the results regarding the total vulnerable funds. Finally, Section VI concludes the paper and gives some guidelines for further research.

II. BACKGROUND

Bitcoin is a *peer-to-peer* currency protocol without any central authority governing the network, presented in 2008 under the pseudonym of Satoshi Nakamoto **whitepaper** *bitcoin*. In the seminal paper, it is explained all the protocol basics, from the public and private key scheme and addresses to transactions, blocks and the network.

Payments in Bitcoin, as in any other currency system, are transfers of coins from the sender to the receiver through *transactions*. They have a predefined structure, as they mainly contain what coins are being spent, named *inputs*, and where are they being sent, called *outputs*. In *outputs*, we find how the user wants to lock the coins and what is needed to spend them, founding this in *scriptPubKey* section. While the *inputs* itself contains, besides much more information, the coins ownership proof. Basically, the proof to demonstrate the whole network that they coins belong to the same user who is spending them. Usually, this is a digital signature plus a public key, but we can find many other proofs. In this case, we find this information in the *scriptSig*.

Unlike other cryptocurrencies, Bitcoin does not use a single “account” for each user, where all your funds is stored. Instead, it allows users to create new unique identifiers each *transaction* they make. This promotes user anonymity, as the amount of coins each user holds is no longer known. They are called *addresses* and also serves another function, encoding the way the users want to lock their coins.

A. Addresses

As mentioned before, *addresses* encode the way users want to protect the coins. They can be seen like a set of instructions, for example, we could find an *address* demanding to make a signature with the private key associated with the public key showed, or maybe user wants to lock their coins to a challenge being the only that can resolve it. This adds flexibility to the

system, giving users freedom to decide how they want to use their coins. In Bitcoin, different address are defined:

1) *Pay To Public Key (P2PK)*:

This *address* will contain the user's **public key in clear text inside the output**, and in order to spend those coins will be necessary only to provide a valid signature generated with the secret key associated, and this signature will be located inside the *input* **learnmeabitcoin**.

2) *Pay To Public Key Hash (P2PKH)*:

This *address* type will hide the public key from the network using a *hash* function, placing the result of the *hash* in the *output*. To unlock and use the coins, it will be necessary provide a valid signature and also the public key associated, in order to verify the *hash* function and the signature. The *hash* and the **public key will be placed in the inputs learnmeabitcoin**.

3) *Pay To Script Hash (P2SH)*:

The *P2SH* address type instead of using the public and private key scheme, allows the user choose how to lock their coins. In order to unlock the coins will be necessary to provide the script used and also the information to execute it, in order to validate it. Those **scripts are placed in the output using a hash function**. Usually, the users tend to wrap other *addresses*, for example we can wrap a *P2PKH* inside a *P2SH*, obtaining a more private *address*. In this specific case, we will have to provide a signature and the public key as well **learnmeabitcoin**. Also, we can find examples of multisignatures schemes, where different public keys are used, and different signatures are needed in order to unlock the coins. In this case, the script is included in the *output* using a *hash* function, **the input will contain all the rest information, including the public keys**.

4) *Pay To Taproot (P2TR)*:

Lastly, we find *P2TR* addresses, that allows users hide the way they want to protect the coins behind a public key, allowing them to use the coins by means of an script or a digital signature. Even using only the script path, the address will use a public key. Similarly to *P2PK*, we will place **the public key in clear text on the output** and the signature or script in the *inputs* **learnmeabitcoin**.

5) *Witness (W)*:

We can also find Pay to Witness Public Key Hash (*P2WPKH*) and Pay to Witness Script Hash (*P2WSH*) **learnmeabitcoin**, but they behave identically in terms of information needed to unlock the coins as its counterparts, so we will not make any distinction between the *witness* and *no witness*.

At that point, it is important to mention that in this paper, we intentionally adopt a common but technically imprecise terminology for ease of exposition. Specifically, we refer to Bitcoin input addresses, Bitcoin output addresses, and input amounts when discussing transaction structure and value flows. Strictly speaking, the Bitcoin protocol and blockchain data model do not contain addresses; rather, they encode locking and unlocking conditions in scripts, from which addresses are derived as higher-level, human-readable encodings. Likewise, inputs in Bitcoin do not carry explicit amounts; they reference previous unspent transaction outputs (UTXOs), whose values are defined in the corresponding prior outputs. We nonetheless use this address- and input-amount-centric language as a convenient shorthand widely

employed in the literature and practitioner discourse.

We will focus solely on addresses that use the public key system, and we will disregard all those that use any other system. These addresses are not very common and therefore do not have a significant impact on the final result. For example, a possible address could be unlocked by finding hash preimages **todd2013hashbounty**, in this case, a quantum computer would have a certain advantage over classical computers, using Grover's algorithm **grover1996fastquantummechanicalalgorithm**.

B. Quantum Vulnerable Addresses

Once we have a clear view where public keys are stored for each particular address, we can start defining the risk that the development of a *CRQC* may suppose to Bitcoin. As we already mention, users perform payments through public transactions, to allow *miners* include their payment in the *blockchain* and confirm it. When the transaction is publicly available, it could imply the disclosure of a public key. Since a *CRQC* is able to compute a private key from a public one, it would be able to generate a valid signature for a transaction spending this coins and stealing them.

Depending on where and when we find this public key disclosure we can create different groups. First, we can categorize the *addresses* depending on the protection they offer once they are already included in the *blockchain*. There exists two groups **morales2025analisi**. On the one hand, we find the **exposed addresses** being those *addresses* that have on the *output*, user's public key in clear text. These are the most vulnerable ones because as soon as someone wants to send some coins to someone else, the receiver will disclosure its public key, enabling any quantum attacker potentially steal its coins. On the other hand, we find the **non-exposed addresses**, that are the ones that hide the public key from the network. This offers more protection, because the public key does not appear in the *output*, instead we find a *hash*, so the quantum attacker can not break the scheme.

The second distinction we can do is related to when is going to happen this public key disclosure. Here we can also find two groups, **Long-Range Quantum Vulnerable (LRQV)** and **Short-Range Quantum Vulnerable (SRQV)**. To this first group belongs the *addresses* types that offer a large time window to compute the private key and perform the attack. The second group however, offers a small time window to attack, because the public key disclosure is produced while the *output* is waiting to be mined (blocks appear each 10 minutes), and once mined and included in the *blockchain*, the output funds cannot be stolen even with the knowledge of the private key. This small time window vulnerability increases the computation requirements of the *CRQC*, making it a much more impractical attack, and for that reason, in this paper, we only focus on compute the amount of *LRQV* funds.

III. STATE OF ART

Even though is a "recent" field, there is a lot of researchers working on it. For example, Chaincode Labs **milton2025bitcoin**, deeply analysed the impact of a *CRQC* in Bitcoin, proposing solutions to the problem. Later on, they presented a following work **MiltonShikhelman2025** quantifying the impact of a *CRQC* in Bitcoin for a fixed period of

time, evaluating the amount of coins that are in risk of a theft, among many other analysis. *Project Eleven* **projecteleven**, from their side, made the same analysis, offering almost a “real time” value of the amount of quantum vulnerable coins.

Our work is innovative in the way of how we compute the total funds at risk. Such final value requires information of the whole *blockchain* and the projects mentioned above, compute the total funds at risk using Google BigQuery **GoogleCloudBigQuery** capabilities to obtain all this information. With this approach, they are trusting the provided Google service in that the information they provide is the exact one appeared in the *blockchain*. Furthermore, the queries they perform to compute the total funds at risk are expensive in terms of computing power, and so in terms of payments to the Google service. Our work, overcomes both problems by leveraging only with information located in the *blockchain* accessible by anyone with a Bitcoin Node and by reducing the cost of the analysis thanks to an optimal storage system that smoothly scales besides the blockchain expansion.

IV. SYSTEM DESIGN

The objectives of our system are the following:

- 1) Analyse the historical evolution of vulnerable coins from the genesis block, evaluated on a block-by-block.
- 2) Guarantee a computationally efficient system to support processing large volumes of data.
- 3) Develop a scalable system architecture capable of sustained long-term operation.
- 4) Use only the available information that the *blockchain* itself serves, without needing to trust third-party entities.

A. Determining LRQV funds

The coins that are at risk are the ones that are unspent, and they are stored in the *blockchain* as a transaction outputs, known as *Unspent Transaction Outputs* - *UTXO*. Normally, Bitcoin wallets store those outputs in what is known as the (*UTXO-Set*). As we already pointed out in Section II, every output represents one address type and belongs to one category, either *LRQV* or *SRQV* and *exposed* or *non-exposed*. *Exposed addresses* are those directly vulnerable since they disclose the public key in clear text in the output. Vulnerable amounts in such addresses are the easiest to detect, since the presence of an exposed address in a *UTXO* implies that all the funds in such *UTXO* are *LRQV*. Address types falling into this category are P2PK, P2MS and P2TR. The *non-exposed addresses* are the ones in which the public key is not directly present in the *UTXO* but it will be revealed when the input that spends such output appears. Address types falling into this category are P2PKH, P2SH, P2WPKH and P2WSH. As we pointed out before, initially *non-exposed addresses* are *SRQV* since the time range during which they are vulnerable is very short, between the time the input spending the output is seen by the network and the time when the spending transaction is included in a block. However, a *non-exposed address* can become an *LRQV* when such address is reused and some *UTXO* has been spent. This situation becomes clear in the example of Figure 1.

When tx_1 is added to the blockchain, the public key corresponding to B_{ne} is not known since B_{ne} is a *non-exposed address*, and the funds stored are non-vulnerable. Later on,




Figure 1. LRQV coins generated due to address reuse

when tx_2 is added to the *blockchain*, funds are moved to C_{ne} , that is also *non-exposed*, and funds remain non-vulnerable. However, when in tx_3 new funds are moved to address B_{ne} , such coins become vulnerable since the *non-exposed address* has become an *LRQV* due to its reuse (the corresponding public key of such address can be found in the input of tx_1). So, notice, that *LRQV* funds not only depend on the address type but also on the users behaviour. Table I summarize the address classification.

Table I
TABLE SUMMARIZING THE RISK OF EACH ADDRESS TYPE

Address type	Public key exposure	Time window
P2PK	exposed	LRQV
P2PKH	non-exposed	SRQV
P2PKH (reused)	non-exposed	LRQV
P2MS	exposed	LQRV
P2WPKH	non-exposed	SRQV
P2WPKH (reused)	non-exposed	LRQV
P2TR	exposed	LRQV

Due to the typical coin flow, we can extract some possible scenarios where *LRQV* coins are created. The first one is when an *exposed address* is used to store the coins. This is the simplest scenario and the more direct one.

In Figure 2, we can see a normal flow of coins between *addresses*. In tx_4 , the address F_{ex} receives some coins, due to the usage of an *exposed address*, this coins automatically become vulnerable. In tx_5 , F_{ex} sends coins to G_{ne} and H_{ex} , where they are *non-exposed* and *exposed addresses* respectively. We can see how now, the vulnerable coins are only the ones held by the *exposed address*, while the other remain secure. Lastly, in tx_6 the address H_{ex} sends coins to a *non-exposed address*, making the coins non-vulnerable again. Note that the “vulnerable” label changes over the time, because the coins are moved to secure *addresses*, and as soon as they do not disclosure the public key, they are protected.

In Figure 3, we can see how an *address* reuse could happen. Even though, using a *non-exposed address* type, as mentioned before, if the user reuse them, they will become a *LQRV* one. This a high risk situation because the user with K_{ne} might think their coins are safe because is using a *non-exposed address* without knowing that its public key is already in the *blockchain*.

Figure 4 shows a case we encounter a similar situation as before. The address N_{ne} receives coins in some *non-exposed address* several times. Once he spends some of the coins locked by the same *address*, he will need to show the public




Figure 2. Creation and elimination of vulnerable coins




Figure 3. Vulnerable coins generated due to address reuse

key in order to validate the signature. The coins found on the other *UTXO* will become vulnerable since the public key is the same, even though, we are talking about different *UTXOs*.




Figure 4. Vulnerable coins due to "hidden" address reuse

B. Counting *LRQV* funds

We are interested in analysing the historical evolution of vulnerable funds from the genesis block, evaluated on a block-by-block granularity. To that end, we need to process each block of the Bitcoin blockchain and keep track of where the funds are located (exposed or non-exposed addresses) and considering the problem of address reuse described in the previous section that turns *LRQV* funds for non-exposed addresses.

The main problem of such analysis is the amount of information that has to be stored and queried to keep track of

the address reuse and its implication on the *LRQV* funds. At present time, the Bitcoin blockchain now takes up to 700 GB, with more than 1,300 million transactions and 600,000 different addresses **blockchain'charts**, so a database approach with standard query requires considerable computer power capabilities and is not sustainable in the long run.

To overcome such bottleneck, we take advantage of a bloom filter **bloom'filters**. Bloom filters are probabilistic data structures that allow a compact way of storing huge amounts of data, their main property being the ability to provide fast pertinence proofs independently of their size. Such a structure allows us to keep a light register of the non-exposed addresses seen in the blockchain and a fast procedure to determine if an address has been reused.

The procedure for keeping track of the *LRQV* funds is based on general counters. On the one hand, we keep track of the total *LRQV* funds that are vulnerable, and, on the other hand, we also keep track the funds in non-exposed addresses that could become *LRQV* due to address reuse.

We parse each Bitcoin block and, for each transaction in the block, we process the outputs and the inputs. For each output address, if the address is an exposed address we add the amount of that output to the total amount of *LRQV* funds. If the address is a *non-exposed address*, we look for it in the bloom filter, and if it is already on it, we add the amount of the output to the total amount of *LRQV* funds. However, notice that in case the non-exposed address has not been previously appeared, we still have to keep track of the amount of such address to deal with the case depicted in Figure 4. To that end, we tag the address as a potential vulnerable, in case that at some point (before the output is spent) the address is reused.

Once outputs are analysed, inputs are then processed. For each input address, if the address is an exposed address, the amount of the input is subtracted from the total amount of *LRQV* funds. If the input address is a non-exposed address, then in case the address has previously appeared in an input (that means it is included in the bloom filter) then the input amount is subtracted from the total amount of *LRQV* funds. If the address has not been previously used in any input, we check if it has been tagged as a potential vulnerable. In that case, we will add the amount to the potential vulnerable amount for that address. In any case, all non-exposed input addresses processed will be included in the bloom filter.

The detailed algorithm pseudocode for the procedure previously described is presented below, Algorithm 1. It covers all the scenarios presented and combines the ideas previously commented. It basically parses every *transaction* in the blocks, check if any *output* is vulnerable, adding the coins amount to a counter and removes the coins that were vulnerable if they are being spent, using the *inputs*. For clarity and to improve readability of the pseudocode, we use abbreviated data structures and variables. Let V denote the total amount of quantum vulnerable funds accumulated. We define P as a map storing balances associated with potentially vulnerable addresses. Finally, R represents the set of reused addresses, which are immediately classified as vulnerable.

C. Implementation details

As we mentioned before, *bloom filters* allows us reduce the search complexity of reused *addresses*, but it also introduces

Algorithm 1 Pseudocode to compute all quantum vulnerable funds

```

1: for all  $b \in \text{blockchain}$  do
2:   for all  $tx \in b$  do
3:     for all  $out \in tx.outputs$  do
4:       if  $out.addr$  is exposed then
5:          $V += out.amount$ 
6:       else if  $out.addr \in R$  then
7:          $V += out.amount$ 
8:       else
9:          $P[out.addr] += out.amount$ 
10:      end if
11:    end for
12:    for all  $in \in tx.inputs$  do
13:      if  $in.addr$  is exposed then
14:         $V -= in.amount$ 
15:      else if  $in.addr \in R$  then
16:         $V -= in.amount$ 
17:      else
18:        if  $in.addr \in P$  then
19:           $V += P[in.addr]$ 
20:           $V -= in.amount$ 
21:          remove  $in.addr$  from  $P$ 
22:        end if
23:         $R \leftarrow R \cup \{in.addr\}$ 
24:      end if
25:    end for
26:  end for
27: end for

```

some errors in the final result. This filter may marks a *non-exposed address* as vulnerable when it is not. In order to reduce this error rate we can tune the parameters. In our case we have used a special type of *bloom filters*, the scalable ones **ALMEIDA2007255**, because in advance we do not know the amount of reused address we will encounter, so we need that the filters once it achieves the maximum amount of values it can hold, resizes itself to continue storing data. We defined an error rate of 0.1%, meaning that every 1000 *addresses* 1 will be wrong classified. This offers us enough precision for our work while maintaining a low space usage.

The data structure that stores the potentially vulnerable coins is a dictionary, with *addresses* as the keys and the associated coins as a values. In our case, and due to the requirements of long-term operation, we decided to move all this data to a SQL database. This design decision affected the overall performance of the program, being the main bottleneck. Even though, being able to run in a dictionary stored in RAM, in long-term it will not be scalable as storing the data in disk, because this structure should contain all the *non-exposed addresses* with coins. They represent almost 60% of the *UTXOset*, around 95 millions of *UTXOs* **mempool-utxo-report**. In worse-case scenario we will have a different *address* each *UTXO*, meaning an entry for each one. This is completely unfeasible for a long term execution.

V. RESULTS

In order to extract the results, we have implemented the algorithm presented above in Python. Here you can find the

source code used **morales2025quantumvulnerable**.

First of all, we will take a look to the historic evolution of the quantum vulnerable *addresses*, depicted in Figure 5. The amount of coins being held by vulnerable *addresses* grows quickly, achieving more than 5 million of Bitcoins.




Figure 5. Historic evolution of total quantum vulnerable funds.

We can also see the evolution divided by *address* types in Figure 6. It is important to note, that almost all the *P2PK addresses* are from Satoshi Nakamoto because he mined all the block himself, obtaining all the *block rewards*.

As mentioned before, the *exposed addresses* are vulnerable since the beginning, but the *non-exposed* ones need to be reused, so we can extract a side analysis from this plot. Even though, not being able to know how many *addresses* are being reused, we can know that this number is quite high because the amount of vulnerable coins also achieve the millions, being a high privacy issue.

Another important thing to take into consideration is the fact that we observe vulnerable coins held by *P2TR addresses* before the activation date. This is due to some experiments made before the official activation date **b10c'spending'p2tr'pre'activation**.




Figure 6. Historic evolution of quantum vulnerable funds divided by *address* type.

Notice that, the Figure 6, is in logarithmic scale, in order to see all *addresses* types represented.

As we observed in Figure 6, at height 100,000 the main quantum vulnerable coins were due to the usage of *exposed addresses*, mainly all of them comes from the block rewards of Satoshi's *addresses*. Since it started to gain popularity and users started to use it, quickly the *address* reuse became the first source of vulnerable coins. It is important to notice

that even though appearing later in the plot, the *P2PWP* and *P2TR* hold almost the same amount of vulnerable coins as *P2PKH*. They became popular because of their advantages and benefits.

The percentage of quantum vulnerable funds can also be computed, as shown in Table II and in Figure 7. At the early stages of Bitcoin, at block height 100,000, nearly two-thirds of the coins were vulnerable. This percentage decreased over time as users moved their coins to more secure *addresses*, but still almost a quarter of them remain vulnerable.

Height	Qv Coins	Total Funds	% of Qv Coins
100,000	3,381,218.96	5,000,050	67.62%
200,000	4,442,990.91	10,000,050	44.43%
300,000	4,941,310.01	12,750,025	38.76%
400,000	4,579,907.38	15,250,025	30.03%
500,000	4,135,267.96	16,750,012.5	24.69%
600,000	3,792,828.94	18,000,012.5	21.07%
700,000	3,647,079.11	18,812,506.25	19.39%
800,000	4,094,156.64	19,437,506.25	21.06%
900,000	4,431,727.82	19,875,003.125	22.30%
944,373	4,985,409.56	20,013,668.75	24.91%

Table II
PERCENTAGE OF QUANTUM VULNERABLE COINS AT DIFFERENT BLOCK HEIGHTS.




Figure 7. Amount of vulnerable and non vulnerable coins per block height.

VI. CONCLUSIONS AND FUTURE WORK

With this work we wanted to examine and compute the amount of vulnerable funds to a CRQC. It is not expected to happen any time soon, due to the problems the scientifics are facing in order to increase the capacity of the computers, but theoretically could exist. With this preliminary results, we can observe the huge problems that affect Bitcoin. The first one and the main objective of this work, an attacker with power enough to develop and run a CRQC, could steal millions of Bitcoins making this protocol practically unusable. The second problem is the *address* reuse. Users are not aware of the privacy risk that is derived from this malpractice, facilitating the work to any attacker that wants to know more about them.

To sum up, we developed a new methodology that do not leverage in third-party entities maintaining the main characteristic of Bitcoin, trust nobody. In addition to that, we have provided a different method to compute this value and obtained similar results validating, from one side our methods, and from the other side, the other approaches.

A. Future Work

In order to expand this work, several ideas can be explored. First we could perform a deeper analysis, taking into account the script *addresses*, *P2SH* and *P2WSH*. With the idea to analyse the script used and detect those users that wrap public keys, because they are also vulnerable to a quantum attack. Second, we could expand our point of view, and look for many other public key disclosures, for example forks from the *mainnet*, like Bitcoin Cash, or layer two protocols, like Lightning Network. Public and private keys are also used, making that any quantum attacker could gather information from there and try to use it in the *blockchain*.

VII. ACKNOWLEDGMENTS

This work is funded by the projects PID2021-125962OB-C33 SECURING/NET and PID2024-156914OB-C43 SAFE-BLOCKCHAIN, funded by the Ministerio de Ciencia e Innovación, la Agencia Estatal de Investigación and the European Regional Development Fund (ERDF); the DANGER Strategic Project of Cybersecurity C062/23, funded by the Spanish National Institute of Cybersecurity through the European Union - NextGenerationEU and the Recovery, Transformation and Resilience Plan.

Un protocolo de enmascaramiento para algoritmos de consenso no lineales e incrementalmente pasivos

Andreu Cecilia

Universitat Politècnica de Catalunya
Avinguda Diagonal, 647, 08028, Barcelona, España
andreu.cecilia@upc.edu

Ramon Costa-Castelló

Universitat Politècnica de Catalunya
Avinguda Diagonal, 647, 08028, Barcelona, España
ramon.costa@upc.edu

Resumen—Este trabajo presenta un protocolo de enmascaramiento para mejorar la seguridad de un protocolo de consenso en sistemas multiagente no lineales. El enfoque propuesto consiste en añadir una señal de enmascaramiento a la salida de cada agente y aplicar un filtro de desenmascaramiento en el agente receptor. Se establecen condiciones suficientes para garantizar que el protocolo de seguridad propuesto preserve el consenso de salida. Además, simulaciones numéricas muestran su efectividad para prevenir ataques de espionaje y de inyección de datos falsos.

Este documento constituye un resumen extendido del trabajo [1], con algunos resultados adicionales.

Index Terms—Sistemas multiagente, control descentralizado, estabilidad de sistemas no lineales.

Tipo de contribución: Investigación ya publicada

I. CONTEXTO

Las infraestructuras críticas modernas, tales como las redes eléctricas, los sistemas de transporte, las redes de telecomunicaciones y los procesos industriales, se implementan cada vez con mayor frecuencia como sistemas de gran escala altamente interconectados. En este contexto, la estrecha integración entre componentes físicos, computacionales y de comunicación da lugar a los denominados sistemas ciberfísicos (CPS). Si bien esta arquitectura permite mejorar la eficiencia, la escalabilidad y la capacidad de supervisión y control, también introduce vulnerabilidades significativas frente a ciberataques, debido al uso de redes de comunicación abiertas para el intercambio de información.

Entre las amenazas más relevantes en CPS se encuentran los ataques pasivos de escucha o espionaje [2], en los que un adversario obtiene acceso a las señales transmitidas sin modificar activamente la comunicación. En arquitecturas de control distribuido, este tipo de ataques puede permitir a un agente malicioso inferir el estado interno del sistema o sincronizarse con la red, comprometiendo la confidencialidad de la información y facilitando ataques más severos. Por tanto, el diseño de mecanismos de seguridad que preserven la privacidad de los datos sin degradar el rendimiento del sistema constituye un problema de gran interés.

En la literatura se han propuesto diversas estrategias para abordar este reto. La Encriptación Homomórfica [3] permite realizar cálculos directamente sobre datos cifrados y ha sido aplicada a esquemas de control y estimación; sin embargo, su uso práctico se ve limitado por la elevada carga computacional y la latencia introducida, especialmente en aplicaciones en tiempo real o con recursos limitados. Por otro lado, la Privacidad Diferencial [4] protege la información mediante la adición de ruido calibrado, pero introduce de forma inherente un compromiso entre privacidad y precisión, lo que impide

alcanzar un consenso exacto. Las técnicas de Defensa de Objetivo Móvil (MTD, *Moving target Defense*) [5] aumentan la resiliencia del sistema mediante la reconfiguración continua de parámetros o enlaces de comunicación, aunque requieren una sincronización cuidadosa y pueden inducir inestabilidades si no se diseñan adecuadamente.

II. CONTRIBUCIÓN

Este trabajo aborda el problema del consenso seguro en sistemas multiagente no lineales mediante una estrategia de enmascaramiento de señales de baja complejidad. Se considera un sistema multiagente homogéneo compuesto por N agentes, cuya estructura de interconexión viene dada por un grafo invariante en el tiempo $\mathcal{G} = (\mathcal{V}, \mathcal{E}, \mathcal{A})$. La dinámica de cada agente está descrita por

$$\dot{x}_i = f(x_i) + Bu_i, \quad y_i = Cx_i, \quad (1)$$

donde $i \in \{1, \dots, N\}$. Aquí, $x_i \in \mathbb{R}^{n_x}$ denota el vector de estados del agente i , $u_i \in \mathbb{R}^{n_u}$ la entrada de control, y $y_i \in \mathbb{R}^{n_y}$ la salida del sistema que se intercambia entre los agentes. Se asume, además, que $n_u = n_y$. La entrada local u_i de cada agente se selecciona mediante un acoplamiento difusivo de la forma

$$u_i = -\kappa \sum_{j=1}^N a_{ij}(y_i - y_j), \quad (2)$$

donde a_{ij} denota los elementos de la matriz de adyacencia $\mathcal{A}$ del grafo conectado $\mathcal{G}$, se garantiza el consenso en la salida de la red para cualquier $\kappa > 0$, es decir,

$$\lim_{t \rightarrow \infty} |y_i(t) - y_j(t)| = 0, \quad \forall i, j \in \{1, \dots, N\}, \quad (3)$$

La principal contribución del artículo es el diseño de un protocolo modular de enmascaramiento y desenmascaramiento que puede integrarse en algoritmos de consenso existentes sin modificar la dinámica de los agentes, la ley de control ni la topología de la red. En el extremo emisor, cada agente incorpora un generador dinámico de enmascaramiento que altera la señal transmitida mediante la adición de una perturbación dependiente del estado. Este generador está formado por un conjunto de osciladores armónicos desacoplados, cuyas salidas se combinan y se procesan a través de una función no lineal localmente Lipschitz. La dependencia explícita del enmascaramiento respecto a la salida del sistema dificulta que un adversario pueda separar la señal real de la perturbación mediante técnicas frecuenciales.

En el extremo receptor, se introduce un filtro de desenmascaramiento asociado a cada enlace de comunicación entrante.




Figura 1. Esquema del protocolo de enmascaramiento.

Dicho filtro permite reconstruir la información necesaria para el control mediante una sincronización asintótica con el generador de enmascaramiento correspondiente, utilizando únicamente señales locales. Este proceso no requiere sincronización explícita entre agentes, semillas aleatorias compartidas ni canales de comunicación adicionales, lo que lo hace adecuado para CPS distribuidos y con restricciones de recursos. Ver la Figura 1.

A partir de las señales filtradas, se define una ley de control distribuida modificada. Bajo supuestos razonables de conectividad del grafo y detectabilidad de un sistema extendido que combina la dinámica del agente y la del filtro, se demuestra que el sistema en lazo cerrado garantiza la sincronización completa de los estados. El resultado principal establece que el consenso se alcanza de forma exacta, independientemente de la amplitud de las señales de enmascaramiento, en contraste con los enfoques basados en privacidad diferencial, en los que el error de consenso es proporcional a la magnitud del ruido añadido.

Desde el punto de vista de la seguridad, el protocolo propuesto impide que un agente malicioso que no conozca el generador de enmascaramiento pueda reconstruir las señales reales a partir de las comunicaciones interceptadas. Mientras que los agentes legítimos alcanzan un consenso exacto, un espía solo puede aproximarse al consenso con un error acotado, cuyo tamaño depende de la intensidad del enmascaramiento. De este modo, el error de estimación del atacante puede incrementarse arbitrariamente sin afectar al funcionamiento de la red protegida, lo que facilita la detección y el aislamiento de agentes maliciosos.

III. VALIDACIÓN

La aplicabilidad del enfoque se valida mediante un caso de estudio basado en un sistema multiagente compuesto por modelos no lineales de tipo *ball and beam* [6]. Este sistema presenta una dinámica altamente no lineal y satisface propiedades de pasividad únicamente en un conjunto acotado del espacio de estados, lo que lo convierte en un escenario exigente para técnicas de ciberseguridad. Los resultados de simulación muestran que, en ausencia de ataques, el protocolo de enmascaramiento preserva la estabilidad y el consenso del sistema incluso en presencia de señales de gran amplitud. En un segundo escenario, presentado en la Figura 2, la inclusión de un agente espía que intenta sincronizarse sin implementar el filtro de desenmascaramiento provoca un error de consenso elevado que conduce a su desestabilización, mientras que los

agentes legítimos mantienen un comportamiento coordinado.




Figura 2. Evolución temporal de: a) la posición de la bola de cada agente y del agente atacante; b) el ángulo de la biga de cada agente y del agente atacante. Los agentes que implementan el protocolo de enmascarado/denmascarado logran sincronización, mientras que el agente adversario permanece desincronizado.

AGRADECIMIENTOS

This work has been partially funded by the project ACROBA, financed by “European Union NextGeneration-EU, the Recovery Plan, Transformation and Resilience, through INCIBE and by the Ministerio de Ciencia, Innovación y Universidades, la Agencia y del Fondo Europeo de Desarrollo Regional (Project DECODER (PID2024-158394OB-C22) funded by MICIU/AEI/10.13039/501100011033/FEDER UE).

REFERENCIAS

- [1] P. Baldomà-Mitjans, A. Cecilia, G. Casadei, D. Astolfi, and V. Puig, “A masking protocol for nonlinear and incrementally passive average consensus algorithms,” *IEEE Control Systems Letters*, pp. 1–1, 2025.
- [2] A. Teixeira, I. Shames, H. Sandberg, and K. H. Johansson, “A secure control framework for resource-limited adversaries,” *Automatica*, vol. 51, pp. 135–148, 2015.
- [3] K. Xu, Y. Niu, and Z. Zhang, “Cloud-based frequency control for multi-area power systems: Privacy preserving via homomorphic encryption,” *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, vol. 54, no. 8, pp. 5172–5184, 2024.
- [4] C. Dwork, A. Roth *et al.*, “The algorithmic foundations of differential privacy,” *Foundations and Trends® in Theoretical Computer Science*, vol. 9, no. 3–4, pp. 211–407, 2014.
- [5] S. Jajodia, A. K. Ghosh, V. Swarup, C. Wang, and X. S. Wang, *Moving target defense: creating asymmetric uncertainty for cyber threats*. Springer Science & Business Media, 2011, vol. 54.
- [6] J. Hauser, S. Sastry, and P. Kokotovic, “Nonlinear control via approximate input-output linearization: The ball and beam example,” *IEEE transactions on automatic control*, vol. 37, no. 3, pp. 392–398, 1992.

Sesión de Formación 1 - Formación y concienciación en ciberseguridad

Concienciación con casos reales: Importancia de una trazabilidad adecuada en el contexto de la PYME

Xabiel G. Pañeda
Universidad
de Oviedo
xabiel@uniovi.es

David Melendi
Universidad
de Oviedo
melendi@uniovi.es

Roberto García
Universidad
de Oviedo
garciaroberto@uniovi.es

Víctor Corcoba
Universidad
de Oviedo
corcobavictor@uniovi.es

Antonio Estepa
Universidad
de Sevilla
aestepa@us.es

Resumen- Contar con sistemas que realicen una buena trazabilidad de las operaciones realizadas en nuestros servicios y sistemas es clave para detectar incidentes, tomar medidas correctivas y acciones legales cuando sea necesario. Esta circunstancia es especialmente relevante en el contexto de las PYMEs que en general no cuentan con personal técnico o supervisión para los servicios externos, pero que sí sufren las consecuencias de manipulaciones y exfiltraciones como cualquier otra empresa.

En este artículo se presenta una experiencia educativa para la concienciación de PYMEs sobre la importancia de la correcta configuración de trazabilidad en su empresa. El plan de concienciación se articula mediante sesiones cortas donde se presenta una píldora formativa basada en 3 casos reales sufridos en PYMEs donde la falta de calidad de los sistemas de trazabilidad impidió tomar acciones legales a las empresas. Dichos casos buscan que el empresario se sienta reflejado, para conseguir un mayor éxito en la concienciación sobre esta problemática.

Index Terms- trazabilidad, concienciación, PYME, píldora de ciberseguridad, casos reales

Tipo de contribución: Formación e innovación educativa

I. INTRODUCCIÓN

Las PYMEs españolas están claramente expuestas a los ciberataques: el CERT de INCIBE gestionó en 2024 un total de 97.348 incidentes, de los cuales 31.540 afectaron a empresas; el informe Hiscox 2025 sitúa en torno al 60% el porcentaje de PYMEs españolas que declararon al menos un ciberataque en el último año. Las PYMEs, por lo general, disponen de escasos recursos técnicos para su protección por lo que son “presa fácil” para ciberdelincuentes. Frente a este panorama, los programas de concienciación en ciberseguridad son considerados uno de los medios más efectivos para mitigar el riesgo humano, y preparar a los empleados para actuar correctamente ante incidentes o amenazas.

Además, una vez ocurrido el incidente, la falta de trazabilidad técnica y probatoria es uno de los principales obstáculos para que los ciberdelincuentes —tanto externos como insiders— puedan ser identificados y finalmente condenados en sede judicial, convirtiéndose en un problema estructural de la ciberseguridad actual.

La Directiva NIS2 destaca la trazabilidad como un elemento clave para la ciberseguridad porque permite reconstruir qué ha ocurrido, cuándo y quién ha intervenido ante incidentes de seguridad, algo esencial tanto para la detección

temprana como para la respuesta y recuperación. Así mismo, el Esquema Nacional de Seguridad [1] la ha incluido como una de las cinco dimensiones de la seguridad, junto con la confidencialidad, la integridad, la disponibilidad y la autenticidad, en línea con iniciativas de estandarización previas como la ISO 7498-2:1989 [2]. La trazabilidad o “no-repudio” tiene implicaciones en la captura y custodia de evidencias con validez jurídica. Por ello, es especialmente importante disponer de garantías durante su generación por parte de los sistemas implicados, durante su captura y estudio y durante su custodia posterior, de ahí que existan marcos de referencia y estándares especializados [3].

Pero a diferencia de otras dimensiones de la seguridad, la trazabilidad es algo ajeno para el público general. Los usuarios no técnicos son más conscientes de otros problemas como pueden ser los fallos de disponibilidad o la pérdida de confidencialidad. Para los usuarios con un perfil más técnico, la trazabilidad es un aspecto al que no se suele dar la misma importancia que a otras dimensiones de la seguridad o requisitos como los de eficiencia, usabilidad, o la mera funcionalidad. Esto se debe a que la trazabilidad es un aspecto que resulta especialmente importante ex post facto y que, por lo tanto, no afecta a la operativa ordinaria de un sistema o a sus características más visibles.

Así, uno de los problemas que hemos detectado en más de 20 años como analistas forenses y peritos es que, a pesar de que en la mayoría de los sistemas existen elementos de monitorización que generan trazas, estas o no son lo suficientemente precisas o completas o no están correctamente configuradas. Las consecuencias pueden ser trágicas al no poder localizar al culpable, determinar fehacientemente la dimensión del incidente o no conservar la cadena de custodia de las evidencias. Por ello, planteamos la necesidad de realizar campañas de concienciación para PYMEs, pero no sobre aspectos defensivos, sino sobre la necesidad de mejora de la trazabilidad.

El objetivo de este artículo es facilitar la realización de campañas de concienciación eficaces que sensibilicen a las PYMEs sobre la importancia de la correcta configuración de las trazas mediante casos reales ocurridos en otras empresas españolas. El resto de este trabajo se ha estructurado como sigue. En la Sección II se comentan los aspectos generales del plan de concienciación. En la Sección III se plantea el enfoque metodológico. En la Sección IV se describen los casos de ejemplo que se emplearían en el plan de concienciación y las reacciones sobre las sesiones en la Sección V. Finalmente, la Sección VI presenta las conclusiones del trabajo y unas posibles ampliaciones.

II. PLAN DE CONCIENCIACIÓN A TRAVÉS DE CASOS REALES

Las PYMEs son, en países como España, uno de los motores más importantes de la economía. Su actividad se reparte por todo tipo de sectores. Desde el punto de vista de la digitalización, este tipo de empresas suele destacar por una implantación de soluciones de tecnología poco ordenada. En algunos casos utilizan personal propio poco formado para llevar estos procesos de digitalización a cabo y en otros casos contratan a empresas especializadas con un escaso nivel de supervisión por falta de conocimientos. Esto crea un caldo de cultivo importante para que se puedan producir problemas de ciberseguridad. No en vano, entidades de carácter público como el INCIBE tienen iniciativas especialmente dirigidas a este tipo de organizaciones [4].

Diversos estudios subrayan la necesidad de estrategias específicas de concienciación de las PYMEs. En el estudio realizado por, Chaudhary et al. [5] se pone de relieve la falta de enfoques diseñados específicamente para las características operativas de estas organizaciones frente a la práctica habitual de realización de campañas de concienciación genéricas. Ponsard et al. [6] defienden la inclusión de componentes emocionales y comportamentales en las actividades de concienciación. Erdogan et al. [7], mediante un estudio en 141 PYMEs del Reino Unido, destacaron la falta generalizada de capacidades y prácticas sostenidas de ciberseguridad, lo que resalta la urgencia de enfoques educativos innovadores, prácticos y ajustados a sus limitaciones reales.

Olabode [8] y Rawindaran [9] coinciden en destacar que los programas efectivos deben enfocarse en el factor humano y contextualizar el aprendizaje. Sin embargo, ninguno de estos enfoques ha sido aplicado a través de estudios de caso forense reales, como se propone en esta experiencia educativa.

En este contexto, se plantea un plan de concienciación para PYMEs sobre la importancia de disponer de una buena trazabilidad. Como se ha comentado, un aspecto importante dentro de la ciberseguridad es la trazabilidad. Permite determinar qué ha pasado en un sistema, lo que es fundamental a la hora de estudiar un incidente, recuperar un sistema comprometido, generar un análisis forense o plantear acciones de mejora.

III. METODOLOGÍA

Este plan se caracteriza por tres elementos relevantes adecuados a la realidad de las PYMEs: una duración mínima, un enfoque práctico y la no necesidad de ningún conocimiento técnico.

La experiencia se desarrolla a través una sesión formativa breve (30-60 min), denominada “píldora formativa”, dirigidas a propietarios, gerentes y responsables de servicios TIC en PYMEs. La sesión se estructura en torno a tres casos reales extraídos de investigaciones forenses realizadas por los dos primeros autores, con más de 20 años de experiencia en ciberseguridad. En la sesión participan 3 especialistas.

El enfoque metodológico se basó en los siguientes principios:

1. Selección de 3 casos relevantes que reflejan situaciones frecuentes en las PYMEs (ERP, almacenamiento en la nube, servidores NAS). Para la selección de los 3 casos se tuvieron en cuenta cuestiones como diversidad, impacto y alineación con el mundo PYME. El número de casos se limitó a 3 para que el tiempo de representación y debate no superara los 60 minutos (estimación de tiempo máximo que un directivo está dispuesto a dedicar).

2. Narrativa sencilla, comprensible para personal no técnico, enfatizando las consecuencias económicas y de negocio de la empresa.

3. Soporte visual con evidencias reales como capturas de logs y registros de auditoría. Las imágenes deben de ser descriptivas de los problemas y alinearse con el funcionamiento observable en las organizaciones de los participantes.

4. Discusión abierta sobre cómo esos casos podrían reproducirse en las empresas participantes. Se plantea un debate para que los participantes puedan plantear la situación de su organización y alinearse con los casos presentados.

5. Recogida informal de impresiones y retroalimentación post-sesión. Puesto que los directivos son reacios a rellenar encuestas, se plantea una recogida de impresiones informal en debates abiertos o conversaciones directas entre los 3 formadores y los asistentes.

Cada caso tenía como objetivo mostrar cómo la ausencia de trazabilidad o el mal registro de eventos dificultaba o impedía tomar acciones correctivas, legales o disciplinarias. También, cómo la imposibilidad de actuar por falta de pruebas produce en sí misma consecuencias indeseables y con difícil solución.

IV. DESCRIPCIÓN DE LOS CASOS DE CONCIENCIACIÓN

A. Caso 1: Manipulación de la contabilidad

Este caso se centra en la manipulación por parte de uno de sus empleados de su sistema de gestión contable. El elemento que se ve afectado desde el punto de vista de la ciberseguridad es la integridad de los datos.

Un cliente se acerca a un local de una óptica e indica que sus gafas están defectuosas, por lo que solicita el reembolso. Al localizar la operación, se le indica que se le van a reintegrar los 100 euros que había pagado por las gafas. No obstante, el cliente revela que el coste de las mismas fue de 150 euros. En el sistema consta que el precio de las gafas era de 150 euros, pero que se realizó un descuento de 50 euros que el cliente niega haber recibido. La empresa investiga la situación para saber qué ha pasado. Se consulta con algunos clientes habituales de la óptica con los que se tiene confianza y todos ellos confirman no haber recibido una serie de descuentos que constan en el sistema. Todos los clientes afectados han sido

Cliente	Venta	Fecha de operación	Autor	Operación
423/ CliCod=32/1		13/03/2023 10:39	10:39:17 Administrador	Consulta
424/ CliCod=323/1		13/03/2023 10:38	10:38:33 Administrador	Consulta
425/ CliCod=325/1 ; VENCod=861/1		13/03/2023 10:37	10:37:18 Administrador	Del Nueva
426/ CliCod=332/1		13/03/2023 10:20	10:20:27 Administrador	Consulta

Fig. 1. Registros de actividad del sistema de gestión de la óptica.




Fig. 2. Informes generales de actividad en un servicio en la nube.

atendidos por un mismo empleado. La hipótesis sobre lo sucedido es que el empleado aplicó los descuentos tras haber generado los tickets de compra y haber cobrado los productos en efectivo. Para confirmar esta teoría, se analiza la actividad del empleado en el sistema de gestión a través de sus registros de log.

Para poder identificar esta situación correctamente, es necesario que el sistema de trazabilidad proporcione información detallada sobre cada una de las acciones realizadas. En la figura 1, se presenta un fragmento del registro de actividad del sistema. En dicho registro constan operaciones de consulta y venta, realizadas por un empleado concreto en una fecha determinada y vinculadas a distintos clientes. El problema es que dicho registro no proporciona información suficientemente detallada para confirmar las sospechas de la empresa. Tal y como se observa en la figura 1, no se registran detalles sobre los importes correspondientes a las ventas ni sobre la aplicación de descuentos.

Debido a una insuficiente trazabilidad de las acciones de los usuarios de sistema, no es posible conseguir una evidencia fehaciente de las acciones fraudulentas realizadas por el empleado e iniciar un procedimiento disciplinario o judicial.

Detrás de esta situación está un diseño incorrecto del sistema de registro de la aplicación de gestión, que debería haber contemplado el almacenamiento de más detalles. Es un aspecto al que no se suele dar importancia durante la adquisición de un sistema o en la contratación de su desarrollo. No tiene un impacto en la operativa diaria de una organización, pero tiene efectos muy perjudiciales durante la resolución de conflictos. En estas condiciones no se puede justificar un despido por causas disciplinarias (art. 54 Estatuto de los Trabajadores).

B. Caso 2: Exfiltración de datos en servicio en la nube

Este caso se centra en una exfiltración de datos relevantes desde un servicio de almacenamiento en la nube contratado por una empresa. En esta ocasión, el elemento que se ve afectado desde el punto de vista de la ciberseguridad es la confidencialidad de los datos.

Un empleado se va de la empresa. A los pocos días llegan rumores de que ha empezado a trabajar para un competidor directo. Algunos clientes indican que el extrabajador los ha visitado, presentándoles proyectos interesantes a un precio muy competitivo. Con la información recabada, se observa que estos proyectos podrían coincidir con los que se estaban preparando en la empresa. Los documentos sobre dichos proyectos se almacenan en un servicio en la nube de uso compartido. Se deciden revisar los registros de actividad de la plataforma para ver si se observa alguna extracción de información. En los informes de actividad agregada que proporciona el proveedor de servicios en la nube, se observa que dicho trabajador sincronizó con su equipo una cantidad especialmente alta de ficheros durante su último mes en la empresa (figura 2, cuadro rojo). El problema es que no es posible saber qué ficheros concretos descargó en su equipo porque la auditoría está configurada por defecto. Sin una evidencia fehaciente de qué información fue extraída es imposible aseverar que los proyectos presentados se basan en otros desarrollados en la empresa. Un proceso judicial sin evidencias de qué información ha sido extraída tiene pocos visos de prosperar.

Detrás de esta situación se encuentra una empresa que utiliza servicios en la nube con una incorrecta configuración de las funciones de auditoría disponibles en la plataforma utilizada. Muchas plataformas de servicios en la nube como Microsoft 365 o Google Workspace cuentan con servicios detallados de auditoría. Pero en muchas ocasiones, estos servicios deben activarse de forma explícita. Por defecto, los registros de auditoría son poco detallados o proporcionan información de tipo general sobre la actividad de los usuarios en un periodo de tiempo limitado. Este problema se puede producir cuando la gestión del servicio se realiza por una sección de la empresa o también cuando se han contratado los servicios a un tercero que se encarga de las tareas de administración del servicio.

Como en el caso anterior, se trata de un aspecto al que no se suele dar importancia durante el proceso de despliegue de los servicios corporativos en una plataforma en la nube. No es

algo que afecte negativamente a la operativa diaria de la organización, pero esta incorrecta configuración de los servicios de auditoría tiene efectos muy dañinos cuando se produce una situación como la descrita. Las consecuencias económicas para empresa pueden ser devastadoras.

C. Caso 3: Exfiltración de datos en almacenamiento NAS

Este caso se centra en una exfiltración de datos relevantes desde un servicio de almacenamiento NAS instalado en la empresa. Tal y como sucedía en el caso anterior, el elemento que se ve afectado desde el punto de vista de la ciberseguridad es la confidencialidad de los datos.

La tensión entre dos socios de una empresa de distribución de material de construcción se incrementa. Tras una reunión, se acuerda que el socio mayoritario compre las acciones al que tiene menor participación y se ponga fin a la relación. Justo el día del acuerdo, un empleado observa que el socio que deja la empresa se encuentra copiando archivos en un disco duro externo. Las sospechas apuntan a un robo de información en un sistema NAS que hay en la empresa, que es donde se almacenan todos los archivos de la organización. El personal técnico revisa los registros de actividad del sistema NAS y confirma las sospechas sobre exfiltración. El socio copió todos los archivos del NAS, incluyendo información sobre los proyectos de la empresa y datos personales sobre los empleados y sus clientes. El personal técnico realiza una exportación de los registros de actividad a un fichero. Se convoca al abogado de la empresa y tras una reunión se decide solicitar un informe pericial. Unos días después, los peritos se personan en la empresa para la recogida de evidencias. Los registros de actividad han desaparecido del NAS. Se ha alcanzado el volumen máximo de registros almacenados por el sistema y se ha realizado una rotación de los logs que ha provocado la desaparición de las entradas del día de la exfiltración. Se plantea un problema importante para iniciar acciones legales. A pesar de que hay constancia de la exfiltración, los peritos no pueden garantizar la cadena de custodia de una evidencia que ya no existe.

A diferencia de los casos anteriores, el personal técnico de la empresa sí había tenido la cautela de activar los registros de auditoría. El problema es que, debido al volumen de actividad de la empresa, las capacidades de registro del sistema NAS son insuficientes. Tampoco afecta negativamente a la operativa diaria de la organización, pero esta insuficiencia de capacidad tiene un efecto muy negativo en este caso. Debería haberse realizado un estudio sobre las capacidades de almacenamiento del sistema de registro del NAS. Alternativamente, una monitorización activa del sistema que hubiese detectado el problema antes de la necesidad. Esta situación se habría evitado mediante el despliegue de un sistema de consolidación y custodia de logs que hubiese evitado la pérdida de los registros dentro de los plazos preceptivos. En la figura 3, se muestran los registros recogidos por el sistema de monitorización y como los registros presentes más antiguos son posteriores al incidente. Con ella, se trata de mostrar cómo las evidencias se han escurrido entre los dedos. La copia realizada por los técnicos no garantiza la cadena de custodia por lo que su validez en un proceso judicial será puesta en entredicho.

V. REACCIONES SOBRE LAS SESIONES

La formación se realizó para diferentes organizaciones empresariales. Cada una de las sesiones generó un alto nivel de participación, debate y reflexión. Los participantes valoraron positivamente el enfoque práctico y reconocieron que los casos reales eran más efectivos que la teoría. Algunas empresas iniciaron revisiones inmediatas de sus políticas de auditoría, configuraciones de seguridad y almacenamiento de logs. Otras encargaron cursos formativos específicos para su personal.

El formato de cápsula formativa permitió adaptar los contenidos a entornos no técnicos, logrando:

- Mayor compromiso emocional con los temas tratados.
- Transferencia directa del conocimiento al contexto propio.
- Mejora en la percepción de la ciberseguridad como responsabilidad compartida.

En las discusiones abiertas y retroalimentación post-sesión se evidenció el desconocimiento sobre la temática de los asistentes. No hubo comentarios de mejora por parte de los asistentes, y, en la mayoría de los casos, se excedió el tiempo previsto de la sesión debido al interés evidenciado por parte de los participantes en la discusión abierta.

VI. CONCLUSIONES Y TRABAJOS FUTUROS

La concienciación relativa a la ciberseguridad es una tarea imprescindible en el contexto actual de rápida adopción de servicios digitales y falta de conocimientos técnicos de los usuarios.

En este artículo presentamos una experiencia educativa a para concienciar sobre la necesidad de contar con una buena trazabilidad en los sistemas y servicios informáticos. Para evitar la necesidad de conocimientos técnicos en los destinatarios, aumentar el impacto y reducir la duración, se basa en la presentación de 3 casos prácticos que han dado lugar a exfiltraciones y manipulación de información, y donde la trazabilidad no fue adecuada para poder llegar a poner en marcha un proceso sancionador o legal. Los casos incluidos son muy representativos de este contexto empresarial. De esta forma, los receptores pueden verse reflejados en las situaciones descritas y valorar qué consecuencias podría tener una inadecuada trazabilidad en sus organizaciones. El diseño de la formación está especialmente adaptada a propietarios y responsables de empresas que no están dispuestos a dedicar demasiado tiempo a este tipo de temas.

Los programas de concienciación en ciberseguridad deben adaptarse a las necesidades y limitaciones de las PYMEs. Esta experiencia muestra que los casos reales forenses, presentados de forma clara y contextualizada, son una herramienta que permite generar conciencia, provocar reflexión organizacional e impulsar cambios de comportamiento.

Este trabajo de concienciación tendrá como continuación el desarrollo de un sistema de análisis de comportamiento de usuarios y entidades (User and Event Behavioral Analytics – UEBA [10]) avanzado capaz de detectar situaciones anómalas, de incumplimientos legales o de las buenas prácticas de la empresa. Este sistema será capaz de poner en marcha acciones de localización y custodia de evidencias para garantizar que en caso de ser necesario se puedan utilizar en un proceso legal.




Fig. 3. Registros de actividad en un sistema NAS.

AGRADECIMIENTOS

Este trabajo ha sido financiado por el Ministerio de Ciencia, Innovación y Universidades, la Agencia y el Fondo Europeo de Desarrollo Regional (MICIU/AEI/10.13039/501100011033/FEDER/UE) a través de los Proyectos PID2024-155581OB-C22 y PID2024-155581OB-C21.

REFERENCIAS

[1] Ministerio de Asuntos Económicos y Transformación Digital “Real Decreto 311/2022, de 3 de mayo, por el que se regula el Esquema Nacional de Seguridad”, en Boletín Oficial del Estado, núm. 106, 2022. <https://www.boe.es/eli/es/rd/2022/05/03/311/con>

[2] ISO 7498-2:1989, “Information processing systems. Open Systems Interconnection, Basic Reference Model Part 2: Security Architecture” International Organization for Standardization, 1989.

[3] ISO/IEC 10181-4:1997, “Information technology. Open Systems Interconnection. Security frameworks for open systems: Part 4 Non-repudiation framework” International Organization for Standardization, 1997.

[4] INCIBE, “Servicios del INCIBE para empresas”, en línea <https://www.incibe.es/empresas> (última vez consultado el 26/03/2024).

[5] Chaudhary, S., Gkioulos, V., & Katsikas, S., “A quest for research and knowledge gaps in cybersecurity awareness for SMEs”, Computer Science Review, 50, 100592, 2023.

[6] Ponsard, C., Grandclaudon, J., & Bal, S., “Survey and Lessons Learned on Raising SME Awareness about Cybersecurity”, ICISSP 2019, 558–563, 2019.

[7] Erdogan, G., Halvorsrud, R., Boletsis, C., Tverdal, S., & Pickering, J., “Cybersecurity Awareness and Capacities of SMEs”, ICISSP, 2023.

[8] Olabode, O., “The Relevance of Cybersecurity Awareness Training for Employees in SMEs”, Bournemouth University, 2022.

[9] Rawindaran, N., “Impact of Cyber Security Awareness in SMEs in Wales”, PhD Thesis, Cardiff Metropolitan University, 2023.

[10] Agencia Española de Protección de Datos, “Análisis de comportamiento de usuarios (UEBA) y protección de datos”, en línea <https://www.aepd.es/prensa-y-comunicacion/blog/analisis-de-comportamiento-de-usuarios-ueba-y-proteccion-de-datos> (última vez consultado el 27/03/2024).

Educating for Impact: A Strategic Vision for Ethereum Security Training

Marco López
Decentralized Security
Málaga, Spain
marco@decentralizedsecurity.es

José Carlos Ramírez
Matter Labs
Porto, Portugal
jc@jcsec.io

Isaac Agudo
NICS Lab, University of Málaga
Málaga, Spain
isaac@uma.es

Abstract—The rapid growth and technical evolution of the Ethereum ecosystem have created a pressing demand for qualified security auditors. Although there are numerous learning platforms—from theoretical courses to gamified challenges such as Ethernaut or Damn Vulnerable DeFi—the path to real-world proficiency remains steep and fragmented. Most educational resources focus on isolated vulnerable code, while real-world audits involve complex protocols. This gap leaves aspiring auditors unprepared for the architectural, strategic, and cognitive demands of production-grade audits. In this paper, we introduce *Faillapop*, a mock Web3 project designed as a pedagogical bridge between advanced hands-on exercises and the complexity of real-world audit contests. It emphasizes system-level reasoning, modular code navigation, documentation analysis, and audit planning. We analyze structural shortcomings in current educational pathways and use contest data to quantify learner drop-off and reward disparities. Beyond education, the realism of *Faillapop* makes it an excellent benchmark for training and testing automated vulnerability detectors and LLM-based analysis tools. We describe its open-source development model, integration into university curricula, and long-term vision as a public good for Ethereum security education. *Faillapop* aims to reduce the entry barrier to smart contract auditing, foster inclusive, practice-based learning, and serve as the foundation for a global Ethereum security education hub rooted at the University of Málaga.

Index Terms—Smart Contract Security, Ethereum, Web3 Education, Vulnerability Discovery, Audit Training

Tipo de contribución: *Formación e innovación educativa*

I. INTRODUCTION

Blockchain technology has gained remarkable traction in recent years, driven by its promise of transparency, immutability, and decentralization. Among its many implementations, Ethereum stands out as the most prominent and widely adopted smart contract platform. On 10 July 2025, its cryptocurrency market capitalization exceeded \$335 billion [20], with millions of transactions executed daily [21]. The ecosystem also hosts a thriving decentralized finance (DeFi) sector, with over \$69 billion in Total Value Locked (TVL) across protocols [22]. This unprecedented growth has fueled the development of increasingly complex decentralized applications (dApps) and smart contract architectures, amplifying both the attack surface and the consequences of security breaches. In particular, critical incidents such as the \$624 million Ronin Bridge exploit in March 2022 and the \$1.4 billion Bybit exploit in February 2025 [27] highlight the enormous financial risks and the severe consequences of security failures in Ethereum.

These risks have highlighted the urgent need for skilled smart contract auditors. However, the path to becoming a

proficient auditor remains steep and fragmented. Beyond mastering Solidity [42] and the Ethereum Virtual Machine (EVM) [14], auditors must also grasp secure development practices, adversarial thinking, and the intricate dynamics of decentralized finance (DeFi) [43], governance mechanisms [15], and protocol-level design. Critically, they must be able to navigate and reason about large, modular code-bases under time pressure, a skill rarely developed through traditional documentation or simple exercises.

In response, the community has created challenge-based platforms like *Capture the Ether* [5], *Ethernaut* [19], and *Damn Vulnerable DeFi* [12], which have become essential for aspiring auditors. Although these platforms provide a valuable starting point, they tend to feature isolated, minimalistic vulnerabilities that not reflect the structural and compositional complexity of production-grade systems. This disconnect becomes especially evident when learners attempt to transition into competitive auditing environments, such as those hosted by *Code4rena* [8] or *Sherlock* [39], where the barrier to entry is high and success is dominated by a small group of elite participants. Such disparities suggest that the learning curve in Web3 security is not continuous, but rather characterized by a sudden and discouraging skill cliff.

To help bridge this divide, we introduce *Faillapop* [23], a novel educational resource designed to simulate the structure and intricacies of real-world Web3 projects while embedding realistic vulnerabilities. With over 950 Normalized Source Lines of Code (nSLOC), *Faillapop* offers a comprehensive environment for end-to-end auditing practice. In contrast to traditional Capture-the-Flag (CTF) platforms, it emphasizes holistic reasoning, adversarial exploration, and structural understanding, core skills essential for real-world audits.

We propose *Faillapop* as an accessible and intermediate learning environment that bridges the gap between CTF-style challenges and production-grade auditing. Beyond individual training, it supports applications in formal education, team-based exercises, and research on automated vulnerability detection. Our study begins by analyzing the current landscape of Ethereum security education and examining leaderboard distributions in public audit contests to empirically demonstrate the existence of the skill cliff. We then detail the design, architecture, and use cases of *Faillapop*, and argue for its adoption as a new educational paradigm to democratize access to advanced security training. Ultimately, *Faillapop* serves as the foundation for a broader educational initiative, rooted in the University of Málaga, that aims to foster a global Ethereum security learning hub.

II. THE CURRENT STATE OF WEB3 SECURITY EDUCATION

The path toward becoming a proficient Web3 security auditor is multifaceted and progressively demanding. It typically unfolds in three stages: (i) theoretical resources, which introduce the fundamentals of blockchain technology [25], distributed systems [30], Ethereum architecture [45], and smart contract [47] development; (ii) hands-on platforms, which reinforce these concepts through interactive, challenge-based exercises focused on security; and (iii) the critical transitional phase before entering public audit contests, where the complexity and expectations increase dramatically.

In this section, we analyze this educational trajectory in greater depth, emphasizing the often overlooked transitional phase between hands-on challenges and production-grade auditing. This structure helps illuminate the key gaps and bottlenecks that learners face as they progress toward professional auditing. We begin by exploring the foundational resources that serve as the entry point to this journey.

A. Theoretical Resources

The foundational layer of Web3 security education is built upon a wide range of theoretical content that introduces learners to blockchain technology, the Ethereum platform, and smart contract [29] development. This material is delivered in a variety of formats, such as online courses, technical documentation, university-level curricula, video tutorials, and books. Some of the most widely adopted resources in this space include:

- *Blockchain: Foundations and Use Cases* by ConsenSys Academy on Coursera [3],
- *Ethereum Developer Bootcamp* by Alchemy University [17],
- *Cyfrin Updraft* learning platform [10],
- *Mastering Ethereum* by Antonopoulos and Wood [2],
- *Ethereum Documentation* [18].

These resources offer excellent entry points for individuals seeking to understand the technical model of Ethereum, the mechanics of smart contract development, and the fundamental design of decentralized applications [38]. However, they often lack depth in the domain of adversarial thinking. Most courses and tutorials are oriented toward building decentralized applications rather than breaking them. This is not a flaw per se; after all, a strong builder mindset is needed to understand design patterns and invariants, but it highlights the need for complementary resources focused on security analysis.

To address this gap, learners must turn to security-oriented training materials that delve into vulnerability classes [7], exploit scenarios [46], and testing strategies [34]. Notable examples include the *Cyfrin Updraft Security* course [11], Owen Thurm's security courses [33], and the *DeFiHackLabs* repository [13], which provides reproducible real DeFi exploits. These resources teach students not only how vulnerabilities arise but also how to identify them, reproduce them, and think like an attacker [34].

However, the ecosystem of theoretical resources remains largely fragmented. Learners are often required to navigate

through inconsistent materials of varying quality, update frequency, and difficulty level. Currently, there is no standardized curriculum that progressively and comprehensively guides students from development fundamentals to security-critical thinking.

The result is a new generation of developers who are capable coders but often ill-equipped to detect subtle bugs, reason about protocol-level safety properties, or conduct systematic security assessments. In the following subsection, we explore the role of hands-on training platforms in addressing these gaps and their effectiveness.

B. Hands-on Training Tools

To bridge the gap between theoretical knowledge and real-world auditing capabilities, a variety of hands-on platforms have emerged in the Web3 ecosystem. These platforms aim to train developers and aspiring security researchers in exploit discovery by simulating vulnerable smart contracts in a gamified, challenge-based format. Among the most prominent are *Capture the Ether*, *Ethernaut*, and *Damn Vulnerable DeFi* (DVD), each targeting a different point along the learner's progression curve.

a) *Capture the Ether*: Created by SMARX, *Capture the Ether* is one of the earliest CTF-style platforms for Ethereum smart contracts. It consists of 20 challenges grouped by vulnerability categories (e.g., lotteries, math, accounts), with an average size of approximately 28 nSLOC. Figure 1 shows the distribution of nSLOC per challenge, highlighting their minimal complexity, ranging from as low as 6 lines to a maximum of 121. While the original platform is somewhat outdated and lacks modern Solidity patterns or DeFi-specific mechanics, it still represents an excellent entry point for beginners. Its concise, focused exercises help users understand fundamental vulnerability classes and develop their security smells without being overwhelmed by complexity. In fact, its educational value has motivated community efforts to keep it accessible: for instance, RareSkills [35] maintains an updated version [36] that removes challenges based on obsolete compiler bugs, upgrades the contracts to recent Solidity versions, and replaces the deprecated testnet with local execution using Foundry [24].

b) *Ethernaut*: Maintained by OpenZeppelin [32], *Ethernaut* raised the bar for educational CTFs by introducing a broader spectrum of vulnerability classes across 33 progressively complex challenges. These exercises explore attack vectors such as proxy patterns [16], or delegatecall misuse. With an average nSLOC of 41 and several levels exceeding 70 or even 100 lines, Ethernaut offers deeper technical insight while maintaining an approachable format. The platform's success lies in its pedagogical clarity, it isolates critical concepts from real-world smart contract design and exposes them in digestible units. However, its main limitation is precisely this abstraction: challenges are deliberately simplified, and the overall difficulty does not scale to match the complexity of production-grade audits. As such, Ethernaut excels as a bridge between basic and intermediate understanding, but does not sufficiently prepare users for high-stakes environments.

c) *Damn Vulnerable DeFi*: DVD represents one of the most advanced hands-on resources currently available. It focuses explicitly on vulnerabilities arising from DeFi

mechanics. Composed of 18 scenarios, each inspired by real-world systems and attack vectors (e.g., flash loans [44], governance, oracle manipulation), it provides learners with an environment that closely resembles actual protocol behavior. The exercises exhibit significantly higher complexity, with an average of 145 nSLOC per challenge, several exceeding 200 lines, and the final level reaching 413. This increase in scale and realism makes DVD a valuable stepping stone for advanced learners. However, the challenges are still self-contained and lack the architectural scale and inter-contract dynamics typical of production-grade protocols.

d) Limitations.: Despite their educational value for initial onboarding, these platforms share a common structural limitation: they operate on tightly scoped, isolated contracts. This design ensures clarity and didactic focus, but abstracts away the systemic challenges found in production audits, such as navigating large codebases, understanding modular architectures, or interpreting partially specified business logic. Moreover, the learning curve beyond these platforms is not linear but exponential: transitioning from challenge-based CTFs to real-world audits demands a leap in analytical maturity, and the ability to work with complex, evolving protocols.

This gap represents a critical bottleneck for aspiring auditors. The next subsection explores this disconnect in greater depth.

C. The Gap Before Public Contests

Despite the educational value of CTF platforms discussed previously, a considerable disparity remains between the skills developed through these exercises and those required for successful participation in public audit contests. This mismatch constitutes a structural bottleneck in the Web3 security learning pipeline, contributing to high dropout and frustration rates among aspiring auditors.

a) The Structural Discontinuity.: Success in public audit contests, such as those hosted by Code4rena or Sherlock, require engagement with production-grade codebases spanning thousands of lines, multiple contracts, business logic layers, and extensive documentation. Such environments demands not only technical proficiency, but also architectural reasoning, prioritization, and communication, skills rarely cultivated in traditional CTFs.

This transition is not incremental, it involves a qualitative leap in cognitive demands, context awareness, and ambiguity management. In the absence of intermediate scaffolding, many technically proficient participants find themselves unprepared for the interpretative and strategic dimensions of real-world audits.

b) Quantifying the Inequality.: To better understand the systemic effects of this discontinuity, we analyzed data from Code4rena’s public contests. Using publicly available leaderboard records for 2,848 rewarded participants and over \$22 million in total payouts, we examined the reward distribution through two complementary perspectives: a Lorenz curve and a cumulative Pareto plot.

Figure 2 reveals a highly unequal distribution. The curve deviates sharply from the line of perfect equality, indicating that a large majority of participants receive negligible rewards while a small minority dominates earnings. The calculated

Gini coefficient exceeds 0.8985, highlighting extreme concentration.

Figure 3 complements this by highlighting the skewed accumulation: the top 15% of participants capture over 90% of total rewards, while the top 1% alone account for more than 38%. This is consistent with power-law behavior often found in winner-takes-most environments.

Together, these analyses portray a reward landscape shaped by extreme inequality. Without intermediate environments that progressively build the skills and judgment required in audit contests, the current ecosystem creates a narrow gate of access, favoring a few while systematically excluding many otherwise capable participants.

c) The Missing Middle.: These data confirm the existence of a missing middle in the Web3 audit learning curve: the lack of structured, realistic, and pedagogically effective environments between training and high-stakes public contests. Participants who complete advanced levels of platforms like Damn Vulnerable DeFi often find themselves unprepared for the interpretative depth and architectural nuance of real audits.

In the absence of dedicated intermediate training environments, learners attempting to bridge this gap must rely on informal and self-directed resources, such as post-mortem analyses of exploited protocols, public audit reports, or codebase dissections of mature projects like *Uniswap* [41], *Aave* [1], and *Compound* [9]. While valuable, these methods lack structure, feedback, and scalability, placing a high cognitive load on learners and limiting their accessibility.

This educational gap not only slows down the development of new auditors but also limits the growth of the Web3 security ecosystem as a whole. In the next section, we introduce *Faillapop* as a response to this missing layer, a structured, realistic, and audit-oriented environment designed to facilitate this critical transition.

III. INTRODUCING *Faillapop*

A. Design Objectives

Faillapop is designed as a pedagogical bridge between advanced hands-on exercises and the complexity of real-world audit contests. It was developed with the following objectives in mind:

- **Realism:** Simulate the complexity and structure of actual Web3 protocols, including modular architectures, access control hierarchies, upgrade patterns, token interactions, and DeFi primitives.
- **Coverage:** Incorporate a wide variety of common Web3 security vulnerabilities, from reentrancy and access control to price oracle manipulation, flash loan abuse, and cross-contract interactions.
- **Auditability:** Provide an environment where learners can conduct full protocol audits, including reasoning over architecture, documentation, invariants, and state transitions.
- **Modular Architecture:** Enable easy extension through new components and custom challenge tracks, supporting long-term evolution.
- **Pedagogical Versatility:** Serve not only individuals learning to audit, but also educators, content creators,




Fig. 1. Comparison of nSLOC per Level in Web3 Security CTFs.




Fig. 2. Lorenz curve of cumulative reward distribution.

and ML researchers building automated vulnerability detectors.

These objectives are not just aspirational, they emerge from the pedagogical void identified in Section 2.3. *Faillapop* is designed to be the missing link that enables a realistic, yet approachable training experience before entering high-stakes audit contests.

B. Platform Architecture and Content

Faillapop is deployed as a realistic, intentionally vulnerable smart contract system modeled after a decentralized second-hand marketplace. The project is structured as a monorepo




Fig. 3. Cumulative reward share by participant percentile.

using Foundry and replicates the conditions of a public audit contest: a complex, self-contained project with full documentation, tests, and deployment script.

The platform is designed to provide an immersive, end-to-end audit experience, enabling learners to explore architectural flaws, inter-contract dependencies, and real-world attack surfaces.

a) System Overview.: At the core of *Faillapop* lies a suite of interconnected contracts, each simulating a distinct component of a decentralized marketplace. These include marketplace operations, dispute resolution, staking mechanisms, upgradeable infrastructure, and governance. Figure ?? illustrates the main components and their relationships.

- **FP_Shop:** The marketplace contract, responsible for item listings, sales, and purchases. Sellers are required to lock collateral to participate. This contract is upgradeable via a proxy pattern.

- **FP_Vault:** Handles staking and fund locking. Ether deposited here is used as collateral for selling, and can be slashed if the DAO resolves a dispute against a seller.
- **FP_DAO:** A decentralized governance contract that enables token holders to vote on disputes and protocol upgrades. Dispute voting follows a commit-reveal scheme.
- **FP_Token:** An ERC20 governance token used for voting on DAO proposals and disputes.
- **FP_PowersellerNFT:** A non-transferable ERC721 badge issued to trustworthy users, granting them special privileges in the marketplace.
- **FP_CoolNFT:** A non-transferable reward NFT issued by the DAO to active community members who participate in governance.
- **FP_Proxy:** An upgradeable EIP-1967 proxy contract for FP_Shop, maintaining storage layout and access control across upgrades.

To simulate real-world auditing conditions, *Faillapop* presents a fully documented, modular smart contract system with embedded common vulnerabilities. Rather than isolating exploits into artificial puzzles, the protocol hides subtle issues, ranging from flawed upgrade mechanisms to token misbehavior and governance edge cases, within realistic workflows. Learners must analyze architectural patterns, trace execution paths, interpret NatSpec documentation, and reason about protocol-level invariants in order to uncover and exploit them. The platform is implemented with Foundry and organized as a monorepo, with tests, deployment scripts, and modular architecture supporting extensibility for focused educational tracks or research experiments. With this immersive structure, participants gain exposure to advanced Web3 security concepts, such as inline assembly [6] vulnerabilities, while learning to analyze real project architectures, simulate audits, and articulate findings in formats used by professional security firms like Trail of Bits [40], Halborn [28], or Hacken [26].

C. Comparison with Existing Platforms

Table I compares *Faillapop* with widely-used hands-on platforms for Ethereum security training across key pedagogical and technical dimensions.

Rather than replacing existing platforms, *Faillapop* is designed to complement them by addressing a distinct stage in the pedagogical continuum. Capture the Ether offer valuable entry-level, vulnerability-specific exercises, while Ethernaut and Damn Vulnerable DeFi (DVD) introduces users to common DeFi patterns and attacks. *Faillapop* fills the critical intermediate space between these gamified platforms and real-world protocol audits: it provides learners with the opportunity to reason about system-level behavior, interact with a cohesive and realistically flawed project, and explore documentation and developer intent. This positions *Faillapop* as a bridge between challenge-based learning and professional auditing practice.

D. Use Cases and Applications

Beyond self-guided learning, *Faillapop* supports a wide range of pedagogical and professional scenarios:

- **Workshops and Bootcamps:** Educators can use *Faillapop* as the central artifact in multi-day training sessions or bootcamps, guiding learners through realistic audits.

- **Internal Security Training:** Web3 projects can onboard junior auditors or security-minded developers by using *Faillapop* to simulate audit workflows in a controlled environment.
- **Content Creation:** Security researchers and content creators can use *Faillapop* as a base for writing blog posts, walkthroughs, and guided analysis.
- **Machine Learning Research:** The annotated nature of *Faillapop*, combined with its similarity to production protocols, makes it an excellent benchmark for training and testing automated vulnerability detectors and LLM-based analysis tools [37].

E. Future Development

The next phase of *Faillapop*'s development focuses on deepening its realism and pedagogical reach through the gradual introduction of production-grade DeFi primitives. This begins with a written analysis of the current protocol's tokenomics, which will guide the design of an internal liquidity pool using a native *Faillapop* token. Based on this foundation, we plan to integrate a flash loan provider and a lending module, enabling mock borrowing scenarios within the platform. These additions will not only increase the architectural complexity of *Faillapop*, but also serve as a natural vehicle for embedding real-world vulnerabilities.

Future expansions include the following directions:

- **Guided Challenge Tracks:** A new CTF-style interface will offer structured levels built directly into the *Faillapop* architecture. These tracks will introduce intermediate learners to the platform through guided discovery of embedded vulnerabilities, progressively building toward an open-ended mock audit phase.
- **Live Ecosystem Alignment:** We aim to keep the platform aligned with cutting-edge developments in Ethereum, incorporating vulnerabilities related to emerging standards such as EIP-7702 [4].
- **Web3 Meets Web2:** A separate front-end DApp is under design, which will deliberately incorporate common Web2 security flaws, such as UI-Spoofin, or XSS, in a Web3 context. This extension aims to demonstrate the real-world interplay between Web2 and Web3 surfaces in recent high-profile exploits.
- **Localization and Accessibility:** To broaden its global reach, *Faillapop*'s documentation will be translated into multiple languages, beginning with Spanish and continuing based on community engagement.
- **Educational Collaborations:** We are exploring partnerships with academic institutions and developer training programs to adopt *Faillapop* as an official framework for simulation-based learning and evaluation.

Rather than expanding arbitrarily, each module in *Faillapop* will be designed with educational intent: new features are introduced only if they enable meaningful, realistic vulnerabilities and deepen learners' understanding of protocol interactions. Through this roadmap, we envision *Faillapop* evolving into a realistic training aligned with the evolving threat landscape.

In the following section, we discuss how *Faillapop* responds to current shortcomings in security education, and

Feature	C. the Ether	Ethernaut	DVD	Faillapop
Avg. nSLOC	28	41	145	950+
Realistic architecture	✗	✗	✓	✓✓
Cohesive DApp simulation	✗	✗	✗	✓
Documentation	✗	✗	✓ (limited)	✓✓
Educational use cases	Low	Medium	High	High
ML training applicability	✓	✓	✓✓	✓✓✓

TABLE I
COMPARISON OF HANDS-ON WEB3 SECURITY TRAINING PLATFORMS.

outlines our roadmap for rigorous evaluation, community engagement, and long-term sustainability.

IV. CONCLUSION AND VISION

Faillapop was born out of a clear need: bridging the gap between theoretical security education and realistic, production-inspired auditing practice. What began as an internal teaching resource has now evolved into a modular, extensible framework capable of supporting advanced security learning and experimentation. Yet, we believe this is only the beginning.

Our long-term vision is to establish a global Ethereum security education hub, rooted in the University of Málaga but open to the broader community. As educators, researchers, and practitioners, we are uniquely positioned to bring this initiative to life. Over the past years, we have actively contributed to blockchain education through a 500-hour university course [31], community workshops, and collaborative research, and we are now building the infrastructure to scale this impact.

This hub will have *Faillapop* at its core, serving as the primary simulation environment. Around it, we plan to:

- **Create high-quality educational content** including videos, blog posts, and workshops focused on audit methodologies, fuzzing techniques, and protocol-level design insights.
- **Support students and early-career auditors** through scholarships, mentorship, and curated learning paths that reduce the entry barrier to impactful security work.
- **Foster a community of practice** by launching *Faillapop* v2.0 as a public resource, organizing hackathons, and facilitating collaboration via dedicated online channels.

At its core, this initiative is about reducing the cognitive and emotional barrier that too often keeps aspiring auditors from reaching their full potential. The gap between basic CTFs and real audits on production protocols is still too wide, often leading to frustration, or dropout. *Faillapop* was built to bridge that gap: to provide a realistic, approachable space where students can build confidence, sharpen their thinking, and explore security with curiosity and purpose.

But this is just the beginning. Our broader aim is to help shape a new educational infrastructure for the Ethereum ecosystem, one where learning is continuous, security is a shared public good, and contributing to real-world impact is within reach. We invite researchers, educators, and ecosystem builders to join us in this mission: by sharing knowledge, building open tools, and mentoring the next generation, we believe we can help make Ethereum not only more secure, but more inclusive and resilient.

ACKNOWLEDGMENTS

This work has been partially supported by GPIE25-055, “Permanent Group for Educational Innovation in Cybersecurity,” under the Innova 2025 Program of the University of Málaga.

REFERENCES

- [1] Aave contracts. <https://github.com/aave-dao/aave-v3-origin>. Accessed: 2025-07-08.
- [2] Andreas M. Antonopoulos and Gavin Wood. Mastering ethereum. <https://github.com/ethereumbook/ethereumbook>. Accessed: 2025-07-08.
- [3] Blockchain foundations and use cases by consensys academy. <https://www.coursera.org/learn/blockchain-foundations-and-use-cases>. Accessed: 2025-07-08.
- [4] Vitalik Buterin, Sam Wilson, Ansgar Dietrichs, and lightclient. EIP-7702: Set Code for EOAs. <https://eips.ethereum.org/EIPS/eip-7702>, May 2024. Ethereum Improvement Proposals, no. 7702.
- [5] Capture the ether. <https://capturetheether.com>. Accessed: 2025-07-08.
- [6] Stefanos Chaliasos, Arthur Gervais, and Benjamin Livshits. A study of inline assembly in solidity smart contracts. *Proc. ACM Program. Lang.*, 6(OOPSLA2), October 2022.
- [7] Jiachi Chen, Mingyuan Huang, Zewei Lin, Peilin Zheng, and Zibin Zheng. To healthier ethereum: a comprehensive and iterative smart contract weakness enumeration. *Blockchain: Research and Applications*, 6(2):100258, 2025.
- [8] Code4rena, public contest platform. <https://code4rena.com/audits>. Accessed: 2025-07-08.
- [9] Compound contracts. <https://github.com/compound-finance/compound-protocol>. Accessed: 2025-07-08.
- [10] Cyfrin updraft learning platform. <https://updraft.cyfrin.io/courses>. Accessed: 2025-07-08.
- [11] Cyfrin updraft security course. <https://updraft.cyfrin.io/courses/security>. Accessed: 2025-07-08.
- [12] Damn vulnerable defi. <https://www.damnvulnerabledefi.xyz>. Accessed: 2025-07-08.
- [13] Defihacklabs repository. <https://github.com/SunWeb3Sec/DeFiHackLabs>. Accessed: 2025-07-08.
- [14] Vikram Dhillon, David Metcalf, and Max Hooper. *Unpacking Ethereum*, pages 37–72. Apress, Berkeley, CA, 2021.
- [15] Maya Dotan, Aviv Yaish, Hsin-Chu Yin, Eytan Tsytin, and Aviv Zohar. The vulnerable nature of decentralized governance in defi. In *Proceedings of the 2023 Workshop on Decentralized Finance and Security*, DeFi ’23, page 25–31, New York, NY, USA, 2023. Association for Computing Machinery.
- [16] Amir M. Ebrahimi, Bram Adams, Gustavo A. Oliva, and Ahmed E. Hassan. A large-scale exploratory study on the proxy pattern in ethereum. *Empirical Software Engineering*, 29(4), June 2024.
- [17] Ethereum developer bootcamp by alchemy university. <https://www.alchemy.com/university/courses/ethereum>. Accessed: 2025-07-08.
- [18] Ethereum documentation. <https://ethereum.org/en/developers/docs/>. Accessed: 2025-07-08.
- [19] Ethernaut. <https://ethernaut.openzeppelin.com>. Accessed: 2025-07-08.
- [20] Ether market capitalization chart. <https://etherscan.io/chart/marketcap>. Accessed: 2025-07-10.
- [21] Ethereum daily transaction chart. <https://etherscan.io/chart/tx>. Accessed: 2025-07-10.
- [22] Total value locked in ethereum defi chart. <https://defillama.com/chain/ethereum>. Accessed: 2025-07-10.
- [23] Faillapop. <https://github.com/jcsec-security/faillapop>. Accessed: 2025-07-08.
- [24] Foundry framework. <https://getfoundry.sh/introduction/getting-started/>. Accessed: 2025-07-08.

- [25] Huaqun Guo and Xingjie Yu. A survey on blockchain technology and its security. *Blockchain: Research and Applications*, 3(2):100067, 2022.
- [26] Hacken. <https://hacken.io/>. Accessed: 2025-07-11.
- [27] Blockchain hacks dashboard. <https://defillama.com/hacks>. Accessed: 2025-07-10.
- [28] Halborn. <https://www.halborn.com/>. Accessed: 2025-07-11.
- [29] Shafaq Khan, Faiza Loukil, Chirine Ghedira, Elhadj Benkhelifa, and Anoud Bani-Hani. Blockchain smart contracts: Applications, challenges, and future trends. *Peer-to-Peer Networking and Applications*, 14:2901–2925, 04 2021.
- [30] Jennifer Li and Mohamad Kassem. Applications of distributed ledger technology (dlt) and blockchain-enabled smart contracts in construction. *Automation in Construction*, 132:103955, 2021.
- [31] University of Málaga and NICS Lab. Blockchain university course. <https://www.nics.uma.es/Blockchain/>. Accessed: 2025-07-11.
- [32] Openzeppelin. <https://openzeppelin.com>. Accessed: 2025-07-08.
- [33] Owen thurm's security courses. <https://youtu.be/DRZogmD647U>, <https://youtu.be/zLnxRvf6IMA>. Accessed: 2025-07-08.
- [34] Luisa Palechor and Cor-Paul Bezemer. How are solidity smart contracts tested in open source projects? an exploratory study. In *Proceedings of the 3rd ACM/IEEE International Conference on Automation of Software Test, AST '22*, page 165–169, New York, NY, USA, 2022. Association for Computing Machinery.
- [35] Rareskills. <https://rareskills.io/>. Accessed: 2025-07-08.
- [36] Rareskills capture the ether updated version. <https://github.com/RareSkills/capture-the-ether-foundry>. Accessed: 2025-07-08.
- [37] Dalila Ressi, Alvis Spanò, Lorenzo Benetollo, Carla Piazza, Michele Bugliesi, and Sabina Rossi. Vulnerability detection in ethereum smart contracts via machine learning: A qualitative analysis, 2024.
- [38] Kaushal Shah, Dhruvil Lathiya, Naimish Lukhi, Keyur Parmar, and Harshal Sanghvi. A systematic review of decentralized finance protocols. *International Journal of Intelligent Networks*, 4:171–181, 2023.
- [39] Sherlock, public contest platform. <https://audits.sherlock.xyz/contests>. Accessed: 2025-07-08.
- [40] Trail of bits. <https://www.trailofbits.com/>. Accessed: 2025-07-11.
- [41] Uniswap contracts. <https://github.com/Uniswap/contracts>. Accessed: 2025-07-08.
- [42] Ziyang Wang, Xiangping Chen, Xiacong Zhou, Yuan Huang, Zibin Zheng, and Jiajing Wu. An empirical study of solidity language features. In *2021 IEEE 21st International Conference on Software Quality, Reliability and Security Companion (QRS-C)*, pages 698–707, 2021.
- [43] Sam Werner, Daniel Perez, Lewis Gudgeon, Arian Klages-Mundt, Dominik Harz, and William Knottenbelt. Sok: Decentralized finance (defi). In *Proceedings of the 4th ACM Conference on Advances in Financial Technologies, AFT '22*, page 30–46, New York, NY, USA, 2023. Association for Computing Machinery.
- [44] Ka Wai Wu. Strengthening defi security: A static analysis approach to flash loan vulnerabilities, 2025.
- [45] Weijia Zhang and Tej Anand. *Ethereum Architecture and Overview*, pages 209–244. Apress, Berkeley, CA, 2022.
- [46] Liyi Zhou, Xihan Xiong, Jens Ernstberger, Stefanos Chaliasos, Zhipeng Wang, Ye Wang, Kaihua Qin, Roger Wattenhofer, Dawn Song, and Arthur Gervais. SoK: Decentralized finance (DeFi) attacks. *Cryptology ePrint Archive*, Paper 2022/1773, 2022.
- [47] Weiqin Zou, David Lo, Pavneet Singh Kochhar, Xuan-Bach Dinh Le, Xin Xia, Yang Feng, Zhenyu Chen, and Baowen Xu. Smart contract development: Challenges and opportunities. *IEEE Transactions on Software Engineering*, 47(10):2084–2106, 2021.

Ciberdelinqüen entre niños y adolescentes en Portugal: un estudio basado en datos del videojuego RAYUELA

Andrea Baños Ramos¹, María Reneses Botija², Mario Castro Ponce¹, Farid Bagheri-Gisour Marandyn¹,
Constança Brito³, Filipe Rodrigues³, Gregorio López López¹

¹Instituto de Investigación Tecnológica (IIT), España

Escuela Técnica Superior de Ingeniería (ETSI), Universidad Pontificia Comillas, España

²Instituto de Investigación Tecnológica (IIT), España

Facultad de Ciencias Humanas y Sociales (CHS), Universidad Pontificia de Comillas, España

³Polícia Judiciária (PJ), Rua Gomes Freire 174, 1150-177 Lisbon, Portugal

abanos@comillas.edu, mreneses@comillas.edu, marioc@iit.comillas.edu, fbagherigisour@comillas.edu,

constanca.brito@pj.pt, filipe.rodrigues@pj.pt, gllopez@comillas.edu

Resumen—Este estudio presenta un análisis exploratorio de los datos recopilados durante la primera edición de la campaña nacional de prevención Missão Cibersegura (2024–2025) en Portugal, que contó con una muestra de 5852 participantes. El análisis se centra en la prevalencia y los factores de riesgo asociados a cuatro amenazas cibernéticas clave: ciberacoso, phishing, online grooming y la difusión de noticias falsas. La metodología expuesta es innovadora, ya que combina la recopilación de datos con una experiencia interactiva y atractiva basada en un videojuego. El principal objetivo es utilizar estos datos para comprender mejor cómo se producen las distintas formas de victimización digital entre menores, así como identificar los factores psicológicos, conductuales y contextuales que los sitúan en mayor riesgo. Por último, este trabajo pretende sentar las bases para un análisis interdisciplinar integral de las amenazas digitales que afectan a los jóvenes.

Index Terms—Ciberamenazas, factores de riesgo, análisis de prevalencia, victimización, jóvenes, videojuego.

Tipo de contribución: Investigación en desarrollo

I. INTRODUCCIÓN

Hoy en día existe una amplia variedad de amenazas cibernéticas que afectan a una gran parte de la población mundial. Diversos grupos dentro de la sociedad siguen sin ser conscientes de estas amenazas y de los riesgos potenciales que conllevan, en particular los adolescentes y menores de entre 10 y 16 años. La identificación de numerosos factores de riesgo puede aumentar la prevalencia de dichas amenazas cibernéticas. Con el fin de examinar estos riesgos, este estudio utiliza un juego serio llamado RAYUELA¹ [www.rayuela-h2020.eu], junto con la recopilación de datos sociodemográficos y cuestionarios relacionados con el apoyo externo y experiencias previas de ciberacoso.

En la era digital contemporánea, los menores están profundamente inmersos en entornos en línea que configuran su socialización, educación e identidad personal. Vectores emergentes, como las plataformas de redes sociales, la denominada “manosfera”, las herramientas de inteligencia artificial y los entornos de aprendizaje gamificados, están transformando tanto la forma en que los jóvenes pueden ser captados

para actividades delictivas como la manera en que pueden convertirse en víctimas de daños en línea [1], [2], [3]. Si bien estos espacios digitales ofrecen oportunidades sin precedentes para la conexión y el aprendizaje, también exponen a los usuarios jóvenes a amenazas diversas y en rápida evolución. Entre las más prevalentes se encuentran el ciberacoso (CB), el phishing, el online grooming (OG) y la exposición a noticias falsas (FN), que en conjunto constituyen un amplio espectro de amenazas cibernéticas que afectan de manera significativa a niños y a adolescentes.

Uno de los principales objetivos de este trabajo es apoyar el desarrollo de campañas de prevención y concienciación en los centros educativos destinados a mitigar estas amenazas cibernéticas. Iniciativas desarrolladas por el Instituto Nacional de Ciberseguridad de España (INCIBE), proporcionando un servicio a familias, jóvenes y profesores de los centros educativos, como Internet Segura for Kids (IS4K) y la estrategia Europea Better Internet for Kids (BIK), promoviendo la creación de entornos digitales más seguros y conformando Centros de Seguridad en Internet. Además, Safer Internet Centre Spain 4.0 (SIC-SPAIN 4.0) es un proyecto que refuerza estas actuaciones y proporciona cobertura a IS4K.

Muchos menores siguen sin ser conscientes del daño que su comportamiento en línea puede causar a otros compañeros. La educación es, por tanto, un ámbito clave de intervención, fomentando un entorno seguro en las escuelas. Las familias también desempeñan un papel crucial, dado que el comportamiento de los menores en distintos contextos sociales está fuertemente influido por su relación con padres, madres o cuidadores.

Pueden implementarse programas de formación específicos en los centros educativos para ayudar a identificar vulnerabilidades entre los menores y promover una evaluación crítica de los contenidos y las interacciones en línea. Además, estos resultados pueden servir de base para la elaboración de políticas en el ámbito educativo, apoyando la integración de medidas de seguridad infantil, protecciones de la privacidad y sistemas de notificación transparentes, como la iniciativa del Plan Director para la convivencia y mejora de la seguridad en los centros educativos y sus entornos (2023), impulsada por

¹Se puede descargar el videojuego y visualizar los escenarios en la pestaña RAYUELA GAME, download the game.

la Policía Nacional y la Guardia Civil. En los casos en los que se identifiquen riesgos o daños graves, los agentes de las fuerzas y cuerpos de seguridad pueden intervenir para llevar a cabo las actuaciones oportunas cuando sea necesario.

II. MARCO CONCEPTUAL DE LAS AMENAZAS CIBERNÉTICAS

El ciberacoso representa una de las formas más prevalentes de victimización en línea y se define como el uso intencional de dispositivos electrónicos para dañar o intimidar a otras personas [4]. A diferencia del acoso tradicional, el ciberacoso trasciende las barreras físicas y temporales, lo que a menudo deriva en daños psicológicos persistentes, como ansiedad, depresión y una disminución de la autoestima [5].

Otra amenaza, cada vez más sofisticada, que afecta a los menores es el phishing, un ciberdelito que emplea mensajes digitales engañosos para obtener información personal sensible. Aunque tradicionalmente se ha asociado a víctimas adultas, investigaciones recientes demuestran que los niños y adolescentes son objetivo de este tipo de ataques debido a su limitada concienciación sobre la seguridad en línea y a su mayor tendencia a confiar en las comunicaciones digitales [6], provocando violaciones directas de la privacidad, robo de identidad y malestar psicológico tras descubrir el engaño.

El online grooming se refiere a un proceso relacional manipulador mediante el cual un agresor cultiva la confianza y la proximidad psicológica y emocional con una persona vulnerable, normalmente un menor o un adulto en situación de riesgo, con el fin de facilitar el abuso o la explotación sexual [7], [8]. En el contexto de este estudio, el online grooming alude a la explotación de plataformas digitales por parte de un adulto que manipula la confianza de un menor para redefinir su percepción de la seguridad y de las interacciones apropiadas, utilizando posteriormente el miedo y la vergüenza como mecanismos de control y secreto.

Por último, la proliferación de las noticias falsas influye de manera significativa en la forma en que los jóvenes usuarios perciben e interpretan la información. Su difusión a través de las redes sociales dificulta la distinción entre contenidos fiables y falsos, haciendo a los jóvenes especialmente vulnerables a la manipulación [9], como la que subyace al grooming o al phishing. Además, las noticias falsas pueden influir en las actitudes de los menores, exacerbar la polarización y debilitar sus habilidades de pensamiento crítico.

En conjunto, estos fenómenos evidencian la complejidad y el impacto del ciberdelito en la vida de los menores. Asimismo, estas amenazas digitales no son estáticas, sino que evolucionan de forma paralela a la innovación tecnológica. Por ello, es esencial definir estrategias de prevención con visión de futuro, que incluyan una educación reforzada, marcos regulatorios sólidos y mecanismos de supervisión proactivos.

II-A. Factores de riesgo comunes a distintas amenazas cibernéticas

Los factores de riesgo son condiciones individuales, sociales y contextuales que incrementan la vulnerabilidad de los menores frente a comportamientos dañinos en línea. Mientras que los factores de protección, engloban las habilidades personales, los recursos sociales y las condiciones ambientales que protegen a los jóvenes frente al daño y fomentan la resiliencia

en los entornos digitales. El análisis conjunto de ambos factores proporciona un marco integral para comprender las experiencias en línea de los menores y para diseñar enfoques informados de protección basados en la evidencia.

Estos factores de riesgo ponen de manifiesto que los cuatro fenómenos, ciberacoso, phishing, online grooming y noticias falsas, están interconectados a través de vulnerabilidades estructurales y psicológicas compartidas. En todos los casos, la limitada alfabetización digital, la inmadurez emocional y la supervisión adulta insuficiente emergen como determinantes centrales (ver Tabla I). Asimismo, el diseño de las plataformas en línea, optimizado para maximizar la participación más que para garantizar la seguridad, genera condiciones sistémicas que facilitan la explotación. Una comprensión holística de estos riesgos requiere integrar perspectivas individuales, sociales y tecnológicas, reconociendo que una prevención eficaz debe combinar educación, regulación normativa y responsabilidad de las plataformas.

III. METODOLOGÍA

III-A. Diseño de la investigación

Con el fin de abordar de manera integral el estudio de los fenómenos de ciberacoso, phishing, online grooming y noticias falsas, se diseñó una serie de ciberaventuras basadas en una extensa investigación preliminar a nivel europeo que combinó cuatro estrategias complementarias de recogida de datos: el análisis de sentencias judiciales [19], entrevistas en profundidad con expertos, agresores y víctimas [15], grupos focales con adolescentes [18], [20] y una encuesta [21]. A partir de estos trabajos, se diseñaron escenarios que permitían medir situaciones y factores de riesgo (ver Tabla II). Además, al inicio del juego se incluyeron tanto cuestionarios validados como preguntas sociodemográficas.

Por razones éticas, la probabilidad de convertirse en agresor solo se midió en dos situaciones concretas: una relacionada con el ciberacoso y otra con el ciberacoso homóforo. La victimización por ciberacoso no se midió directamente dentro del juego, sino a través de cuestionarios validados. En el resto de los fenómenos potencialmente delictivos, la probabilidad de victimización se evaluó mediante situaciones de riesgo específicas. El phishing se midió a través de la acción de hacer clic en un enlace falso. En el caso del online grooming, estas incluyeron la aceptación de solicitudes de amistad de desconocidos y el envío de fotografías. Por su parte, las noticias falsas se evaluaron considerando prácticas inadecuadas para verificar la veracidad de la información. En este sentido, otorgar mayor importancia a la apariencia de exactitud de la información, la presencia de gráficos y estadísticas, o al aspecto profesional del sitio web se consideró menos recomendable y más arriesgado que otras estrategias, como comprobar la fuente de la noticia o realizar búsquedas adicionales en internet para contrastar la información.

Las medidas recogidas dentro del juego fueron validadas mediante validez de constructo [22] y validez de criterio [23]. La primera se refiere a la medición de un factor latente subyacente que no se observa directamente. En este caso, los escenarios del juego buscan medir cada uno de los ciberdelitos analizados. La segunda está relacionada con la capacidad predictiva, examinando en qué medida las variables del juego predicen constructos no observados.

Tabla I: Factores de riesgo identificados en investigaciones previas.

Fenómeno	Factores individuales	Factores sociales / contextuales	Factores tecnológicos / de plataforma
Ciberacoso	Baja autoestima y alta impulsividad [10], género, orientación sexual u origen migrante	Entornos conflictivos, supervisión parental insuficiente, bajo apoyo de pares	El anonimato reduce la empatía y facilita la agresión [11]
Phishing	Menor edad, impulsividad y experiencia digital limitada [12]	Compartición de información personal	Mensajes de <i>phishing</i> altamente personalizados a partir de datos en línea [13]
Online grooming	Soledad emocional, baja autoestima, problemas de salud mental o abuso previo [14], género [15]	Supervisión parental insuficiente y búsqueda de validación adolescente [16]	Acceso a datos personales que permite una manipulación adaptada
Noticias falsas / desinformación	Bajo pensamiento crítico y baja alfabetización mediática [9], sesgo de confirmación [17], impulsividad	Alta dependencia de redes sociales como fuente informativa	Diseño atractivo o “científico” que incrementa la credibilidad y la difusión de contenidos falsos [18]

Tabla II: Factores de riesgo medidos (dentro y fuera del juego).

Factores de riesgo	Cuestionarios y registro	Escenarios dentro del juego
Victimización previa por CB	Victimización previa por CB	—
Conducta previa como agresor en CB	Conducta previa como agresor en CB	Conducta previa como agresor en CB
Apoyo / Comunicación familiar	Apoyo familiar	Comunicación familiar
Apoyo social	Apoyo social	—
Autoestima	Autoestima	—
Género	Género	—
Edad	Edad	—
Tiempo en línea	Tiempo en línea	Tiempo en línea
Sociabilidad	Sociabilidad	Sociabilidad
Información personal en línea	—	Información personal en línea
Tipo de centro educativo	Tipo de centro educativo	—

III-B. Tamaño muestral

La muestra inicial estuvo compuesta por 5852 participantes, que se utilizará para otro análisis de tendencias. Sin embargo, este estudio utiliza mayor control y precisión, 1984 individuos fueron retenidos para el análisis tras excluir a aquellos que indicaron tras finalizar el juego, que no habían jugado de la misma forma en que se comportarían en la vida real. Esta muestra final incluyó a 998 chicos, 950 chicas y 7 estudiantes no binarios, con edades comprendidas entre los 10 y los 16 años, en Portugal. Se empleó una estrategia de muestreo no probabilístico por conveniencia, utilizando los centros educativos como puntos de acceso, lo que permitió incluir un gran número de participantes, pero limita la representatividad estadística estricta. La muestra está compuesta predominantemente por estudiantes de centros públicos (aproximadamente el 91 %), con una menor proporción procedente de instituciones privadas (8,4 %) y un número residual de otros tipos de centros. Esta distribución refleja, en cierta medida, el predominio de la educación pública en Portugal, aunque la educación privada está infrarrepresentada en la muestra. Además, el 73 % de los participantes procedía de áreas urbanas y el 27 % de áreas rurales, garantizando la inclusión de contextos territoriales diversos. Los participantes fueron reclutados a través de centros educativos que formaban parte del programa de la Policía Judicial “Missão Cibersegura”.

Aunque el diseño muestral no permite una generalización inferencial estricta, el gran tamaño de la muestra proporciona un alto nivel de precisión estadística. Bajo supuestos estándar (nivel de confianza del 95 % y máxima variabilidad), el margen de error estimado sería de aproximadamente $\pm 2,2$ %. En conjunto, si bien la muestra no puede considerarse plenamente representativa, su tamaño y heterogeneidad respaldan la solidez analítica de los resultados, que deben interpretarse con cautela en términos de generalización.

III-C. Comité de Ética

Se obtuvo la aprobación del comité de ética y todos los participantes (y sus familias, cuando fue necesario) firmaron un consentimiento informado en el que se proporcionaba información completa sobre los objetivos del estudio.

III-D. Procedimiento de recogida de datos

El videojuego se llevó a cabo durante el horario lectivo en las aulas, bajo la supervisión de un docente responsable de su implementación. Se siguió un protocolo previamente establecido que incluía tres fases principales: en primer lugar, la preparación, instalación del juego y la recogida de los formularios de consentimiento; en segundo lugar, la presentación del estudio al alumnado, el registro de los estudiantes y las instrucciones para jugar las seis aventuras; y, finalmente, una serie de preguntas destinadas a una discusión guiada con los estudiantes, que incluían información práctica sobre cómo denunciar incidentes o buscar ayuda en situaciones concretas.

III-E. Análisis de datos

Tras la recogida de los datos, estos fueron exportados y analizados mediante RStudio, versión 2024.09.0-375, un entorno de desarrollo integrado para el lenguaje de programación R. Se realizó un análisis descriptivo de frecuencias simples y un análisis bivalente mediante tablas de contingencia y el test de chi-cuadrado (χ^2), comprobando la significación estadística entre pares de variables a través de los residuos tipificados corregidos. Asimismo, se llevó a cabo un análisis de regresión logística con el fin de evaluar simultáneamente los distintos factores de riesgo, junto con un análisis de colinealidad.

IV. RESULTADOS

IV-A. Ciberacoso

IV-A1. Agresión: Este análisis examinó la probabilidad de convertirse en agresor en contextos de ciberacoso. Dentro del juego se evaluaron dos escenarios: compartir un meme

ofensivo sobre un compañero de clase (N = 1717) y reírse de una broma homófoba dirigida a otra persona (N = 1166).

Ambas situaciones mostraron una prevalencia similar, de un 19,5 % y un 16,3 % respectivamente, incurriendo en conductas agresivas (ver Figura 1). De manera relevante, cuando se pidió a los estudiantes que reflexionaran sobre sus acciones, alrededor del 69,5 % de quienes habían actuado como agresores reconocieron que su comportamiento era incorrecto y muchos lo identificaron explícitamente como una forma de acoso.

La relación entre estas variables es elevada, ya que ambas se midieron dentro del juego, aunque en aventuras distintas relacionadas con el ciberacoso. Esta asociación quedó respaldada por un coeficiente de χ^2 de 50,197 (indicativo de una asociación fuerte) y un valor de $p < 1,39 \times 10^{-12}$, lo que refleja una significación estadística muy alta.

IV-A2. Victimización: Aunque la victimización no se midió directamente dentro del juego, esta se estimó mediante un cuestionario sobre victimización previa (N = 1984), el cual mostró una prevalencia del 28,3 % (ver Figura 1).

IV-B. Phishing

Si bien el phishing suele recibir menor atención en los programas de prevención, emergió como el ciberdelito más frecuente entre los participantes (N = 1046), con una prevalencia potencial del 41 % (ver Figura 1).

IV-C. Online Grooming

La exposición al online grooming se evaluó a través de dos escenarios: la aceptación de una solicitud de amistad de un desconocido en una red social (N = 1295) y el envío de fotografías tras recibir una petición de ese mismo desconocido, que se hacía pasar por un fotógrafo y ofrecía la creación de un portafolio de modelaje (N = 1293).

Los resultados revelaron que el 22,5 % de los participantes aceptó la solicitud sin comprobar el perfil del desconocido (ver Figura 1). Además, entre quienes sí revisaron el perfil, el 16,4 % aceptó igualmente la solicitud, ya que la cuenta incluía indicios realistas frecuentemente utilizados por los agresores, como amigos en común, publicaciones antiguas, comentarios y fotografías reales. Finalmente, el 10,4 % de la muestra total aceptó enviar fotografías.

IV-D. Noticias falsas

El riesgo de caer en noticias falsas se evaluó mediante un escenario en el que los jugadores debían decidir las mejores estrategias para comprobar la veracidad de una información relacionada con personas refugiadas (N = 1118). Se consideró que los participantes estaban en riesgo cuando elegían como primera opción confiar en la apariencia de exactitud de la información y en el aspecto profesional del sitio web. Por el contrario, se consideró que no estaban en riesgo cuando optaban por comprobar la fuente de la noticia o realizar búsquedas adicionales en internet para contrastar la información.

Los resultados muestran que aproximadamente dos tercios de los participantes respondieron de forma adecuada para evitar este tipo de engaño. Sin embargo, un tercio decidió que lo más conveniente era confiar en los aspectos más superficiales de la noticia, en lugar de llevar a cabo una verificación más exhaustiva (ver Figura 1).




Figura 1: Prevalencia de ciberamenazas. Ciberacoso (agresión) se refiere al escenario de compartir un meme de un compañero de clase en el videojuego, y Online grooming se refiere al escenario de aceptar una invitación de un extraño en una red social.

IV-E. Factores de riesgo comunes a todas las amenazas cibernéticas

Uno de los hallazgos más relevantes es la superposición de factores de riesgo entre las cuatro amenazas cibernéticas analizadas, lo que sugiere que las estrategias de prevención dirigidas a estos factores pueden tener efectos protectores amplios (ver Tabla III).

A partir de estos resultados, se destacan los siguientes factores transversales:

- **Género:** Los chicos presentaron una mayor probabilidad de convertirse en agresores en contextos de ciberacoso (especialmente en situaciones homófobas), así como de ser víctimas de phishing, noticias falsas y, de forma aún más marcada, de online grooming.
- **Divulgación de información personal:** En una red social simulada, se pidió a los participantes que decidieran si hacer público su perfil, compartir fotografías personales, publicar su lugar de residencia y elegir una contraseña. Los cuatro comportamientos se asociaron con un mayor riesgo en todas las amenazas cibernéticas analizadas.
- **Comunicación familiar:** Una comunicación débil en el entorno familiar emergió como un factor común en todas las amenazas. Asimismo, el bajo apoyo familiar, medido mediante un cuestionario validado, mostró asociaciones significativas.
- **Tiempo de uso de internet:** En línea con observaciones previas, el uso intensivo de internet se confirmó como el segundo factor de riesgo más relevante para la mayoría de amenazas cibernéticas. Este resultado se observó tanto en las respuestas directas de los participantes como en las situaciones evaluadas dentro del juego.

El tiempo dedicado por agresores y víctimas en cada uno de los escenarios de amenazas cibernéticas, en comparación con las personas que no pertenecen a estas categorías, presenta diferencias significativas. Tanto las víctimas (de las diferentes amenazas cibernéticas) como los agresores completaron las aventuras en menos tiempo durante el juego (ver Figura 3).

Por lo tanto, se confirma la hipótesis de que el tiempo necesario para responder a los escenarios del juego varía entre los distintos grupos.

Tabla III: Factores de riesgo a través de las distintas amenazas cibernéticas.

Factor de riesgo	CB agresión*	CB victimización	Phishing	Online grooming	Noticias falsas
Género	Masculino	X	Masculino	Masculino	Masculino
Edad	Mayor	Mayor	X	Mayor	X
Autoestima	Baja	Baja	X	X	Baja
Apoyo social y otros apoyos	Bajo	Bajo	X	Bajo	Bajo
Tiempo en línea (en el juego)	Alto	Alto	Alto	Alto	X
Tiempo en línea (registro)	X	Alto	Alto	X	X
Apoyo familiar (en el juego)	Bajo	Bajo	Bajo	Bajo	Bajo
Apoyo familiar (cuestionario)	Bajo	Bajo	Bajo	X	X
Información personal en línea – Perfil	Público	X	Público	Público	Público
Información personal en línea – Lugar	Real	Real	Real	Real	Real
Información personal en línea – Fotos	Real	Real	Real	Real	Real
Información personal en línea – Contraseña	Insegura	X	Insegura	Insegura	Insegura
Rasgo de sociabilidad (en el juego)	Alta	X	X	X	X
Rasgo de sociabilidad (cuestionario)	Alta	X	X	X	X
Tipo de centro educativo (cuestionario)	Público	Público	Público	Público	X

Nota: La descripción (categoría relevante) de los factores de riesgo que afectan a diferentes amenazas cibernéticas están representados en esta tabla. Las casillas representadas con una “X” indican que no existe ningún tipo de relación. * Se evalúa el escenario de compartir un meme ofensivo. Al considerar el escenario de la broma homófoba, resultan relevantes los mismos factores de riesgo, con excepción de la edad, la autoestima y la sociabilidad (medida dentro del juego).




Figura 2: Asociación entre ciberamenazas y factores de riesgo. Las asociaciones de χ^2 comprenden diferentes rangos de valores dependiendo del tipo de ciberamenaza: ciberacoso (agresión) $\in [6, 2; 25, 1]$, ciberacoso (victimización) $\in [0, 1; 129, 4]$, phishing $\in [0, 3; 35, 6]$, online grooming $\in [0, 4; 66, 8]$ y noticias falsas $\in [0, 7; 10, 9]$.

V. DISCUSIÓN

V-A. Ciberamenazas

Se identifican dos hallazgos principales. En primer lugar, las tasas de prevalencia de los distintos ciberdelitos son considerablemente elevadas, lo cual resulta preocupante si se tiene en cuenta que el estudio se desarrolló en una situación relativamente controlada, como es el entorno habitual del aula. En segundo lugar, se observa una superposición entre los




Figura 3: Tiempo empleado jugando al videojuego. Las situaciones de victimización medidas dentro del juego ponen de manifiesto conductas de riesgo (ser víctima) o conductas seguras (no ser víctima de la situación de riesgo).

factores de riesgo y los distintos tipos de ciberdelitos. En el apartado siguiente se analizan de forma individual cada uno de los ciberdelitos y sus factores de riesgo asociados, para posteriormente ofrecer una discusión conjunta.

V-A1. Ciberacoso: Los resultados relativos al ciberacoso se basan en dos medidas diferentes. La medida de victimiza-

ción previa donde aproximadamente un tercio de los participantes la reportó, lo que constituye una cifra preocupante.

Las cifras relativas a la agresión también resultan alarmantes. Una prevalencia de aproximadamente el 17,9 % de conductas agresivas y, alrededor del 69,5 % de quienes habían actuado como agresores reconocieron que su comportamiento era incorrecto y muchos lo identificaron explícitamente como una forma de acoso.

No obstante, la prevalencia debe interpretarse únicamente en términos de jóvenes en riesgo de convertirse en agresores, y no como agresores reales. A pesar de la elevada validez ecológica del juego, la ausencia de daño real hacia otras personas puede haber incrementado ligeramente las respuestas de los participantes.

V-A2. Phishing: Esta ciberamenaza afectó a casi la mitad de la muestra de participantes. De manera relevante, la edad no resultó ser un factor significativo [12], lo que indica que, incluso en una muestra amplia, los jóvenes no están desarrollando progresivamente las habilidades necesarias para gestionar este riesgo a medida que crecen.

V-A3. Online Grooming: La elevada prevalencia de decisiones de riesgo en los escenarios de online grooming evidencia que las estrategias preventivas tradicionales resultan insuficientes, como “no aceptar solicitudes de desconocidos” o “no enviar fotografías” (más de uno de cada diez participantes estuvo dispuesto a hacerlo). La progresión observada en el juego, desde la aceptación de una solicitud hasta el envío final de fotografías, refleja la escalada gradual característica de los procesos reales de online grooming y muestra cómo los límites de los adolescentes pueden desplazarse rápidamente cuando se establece confianza o curiosidad.

Además, la aceptación de perfiles aparentemente legítimos sugiere que los jóvenes sobreestiman su capacidad para detectar riesgos, lo que subraya la necesidad de campañas educativas centradas en el desarrollo de competencias críticas y realistas para identificar amenazas en entornos digitales.

V-A4. Noticias falsas: En este caso, tampoco se midió la prevalencia directa, sino el riesgo de caer en desinformación a partir de la confianza en criterios de veracidad poco fiables, como la afinidad o confianza en la persona que comparte el contenido, el grado de sofisticación en el diseño de la fuente de información [24], así como el hecho de que el contenido esté patrocinado e incluya datos y estadísticas [25], [18].

V-B. Factores de riesgo

El estudio ilustra la relación entre variables individuales, sociales y contextuales como factores de riesgo y su conexión con distintos ciberdelitos, poniendo de manifiesto que dichos factores son, en gran medida, compartidos entre todos los tipos de ciberdelito analizados.

- **Divulgación de información personal:** Una de las asociaciones más fuertes observadas en la Figura 2 se da entre la información personal compartida en línea y el phishing, el online grooming y las noticias falsas, lo que confirma que niveles elevados de autoexposición digital incrementan significativamente la vulnerabilidad, ya que estos dependen en gran medida de la explotación de información. Conductas como hacer público el perfil, compartir fotografías, publicar el lugar de residencia o el centro educativo y utilizar contraseñas débiles se

asociaron con un mayor riesgo. Este resultado respalda investigaciones previas que subrayan la importancia de los ajustes de privacidad y de una autopresentación cautelosa en entornos digitales [26]. Por lo que, las estrategias de prevención deberían priorizar la alfabetización en privacidad y el control de la autopresentación, enseñando a los adolescentes a auditar su huella digital.

- **Tiempo de uso de internet:** En el marco del estudio, el tiempo pasado en línea se identificó como el segundo factor de riesgo más relevante, mostrando su asociación más fuerte con el phishing. La presencia excesiva en entornos digitales se ha vinculado previamente con comportamientos impulsivos, una menor autorregulación y una mayor exposición a estresores sociales o emocionales [27]. Además, tanto posibles víctimas como agresores dedicaron menos tiempo en responder las preguntas del videojuego, lo que evidencia una tendencia a actuar de forma impulsiva. Por ello, la prevención debería centrarse en el fortalecimiento de la autorregulación, el control de la atención y el establecimiento de rutinas digitales saludables.
- **Género:** El género muestra una asociación moderada con la perpetración de ciberacoso (CB), el online grooming y, en menor medida, con el phishing y las noticias falsas, en consonancia con los resultados obtenidos y con estudios previos [28]. El mayor riesgo observado en los chicos puede estar influido por normas de género relacionadas con asumir riesgos, la sobreconfianza o la creencia de que las amenazas digitales son mínimas. Este hallazgo subraya la importancia de abordar los roles de género en las estrategias de prevención.
- **Edad:** Esta variable, como factor de riesgo, mostró un patrón diferenciado según el tipo de ciberdelito. En nuestros datos, la edad se asoció tanto con la agresión como con la victimización por ciberacoso (CB), así como con el online grooming (OG), especialmente en la adolescencia temprana y media, etapas caracterizadas por mayor reactividad emocional y vulnerabilidad social. Estas características del desarrollo pueden intensificar tanto la perpetración (por ejemplo, impulsividad, búsqueda de estatus, menor empatía) como la vulnerabilidad (por ejemplo, deseo de aceptación social, susceptibilidad a la atención en línea) [29], [16]. Sin embargo, la edad no redujo la vulnerabilidad frente al phishing ni a las noticias falsas, lo que indica una escasa adquisición espontánea de competencias protectoras, de modo que el aumento de la edad no se traduce automáticamente en una mejor detección de mensajes fraudulentos o desinformación. En conjunto, estos hallazgos sugieren que los riesgos de ciberacoso y online grooming alcanzan su punto máximo durante las transiciones evolutivas, mientras que los riesgos asociados al phishing y a la desinformación se mantienen elevados a lo largo de toda la adolescencia, lo que subraya la necesidad de una instrucción explícita sobre el engaño digital.
- **Comunicación y apoyo familiar:** La comunicación y el apoyo familiar débiles actúan como un factor general de vulnerabilidad frente a distintos ciberriesgos analizados. Este resultado coincide con la literatura sobre mediación parental y seguridad digital: aunque los vínculos directos

con el phishing siguen siendo escasos, diversos estudios indican que la baja supervisión familiar y una comunicación deficiente aumentan la exposición a la victimización en línea y a conductas de riesgo [30], [31]. Los hallazgos sugieren que el diálogo abierto dentro de las familias resulta más eficaz que el control o las restricciones, tanto para prevenir como para detectar amenazas digitales. La falta de orientación en las prácticas digitales favorece decisiones impulsivas. Las intervenciones deberían reforzar el diálogo abierto, y no la vigilancia, fomentar el uso compartido de tecnologías y entornos seguros de comunicación. Asimismo, los centros educativos podrían ofrecer talleres dirigidos a familias sobre normas digitales, estafas, señales de grooming y tácticas de phishing.

- Autoestima: Esta variable, como factor de riesgo, muestra una fuerte asociación con la victimización y una relación moderada con el phishing. Aunque la evidencia previa ha vinculado la baja autoestima principalmente con la cibervictimización en general [32], nuestros resultados sugieren que sus efectos psicológicos indirectos, como la necesidad de validación, la vulnerabilidad emocional o la indecisión, también pueden aumentar la susceptibilidad a intentos de phishing. Por ello, la prevención no debería centrarse únicamente en programas de alfabetización digital, sino también en programas de aprendizaje socioemocional. De este modo, resultaría útil educar sobre cómo los delincuentes explotan la inseguridad personal y emplean estrategias de manipulación.
- Apoyo social: Se observa una asociación particularmente fuerte entre bajos niveles de apoyo social y la victimización por ciberacoso, así como una relación destacable con la susceptibilidad a las noticias falsas. Esto sugiere que redes de apoyo más débiles pueden dejar a los adolescentes más expuestos a la manipulación o a la exclusión. El apoyo social actúa como un factor protector, especialmente frente a riesgos de naturaleza emocional. Por lo que, las estrategias de prevención deberían orientarse a fortalecer el sentido de pertenencia y las redes de iguales.
- Tipo de centro educativo: Se ha identificado una asociación moderada entre el tipo de centro (público) y el phishing, lo que refuerza que factores ambientales y estructurales, como una menor alfabetización digital o menos recursos en ciberseguridad, pueden desempeñar un papel relevante. Sobre todo, adolescentes de contextos educativos más desfavorecidos con mayor vulnerabilidad al phishing [33], debido a habilidades cognitivas más débiles o a un menor rendimiento académico. Por ello, la implementación de currículos gratuitos y estandarizados de alfabetización digital en todos los centros educativos es clave para garantizar un acceso equitativo a la educación en ciberseguridad.

V-C. Limitaciones

A pesar de la amplitud y la alta validez ecológica del videojuego, es necesario reconocer varias limitaciones. En primer lugar, aunque el uso de un videojuego inmersivo proporciona un entorno realista para observar los comportamientos en línea de los adolescentes, los escenarios simulados no pueden reproducir perfectamente las presiones emocionales, sociales

y contextuales propias de las interacciones digitales reales, dando lugar a una ligera sobreestimación o subestimación de las conductas de riesgo.

En segundo lugar, el diseño se apoya parcialmente en medidas de autoinforme para algunas variables (por ejemplo, victimización previa o apoyo familiar), las cuales están inherentemente influenciadas por sesgos de recuerdo y deseabilidad social. La combinación de ambos tipos de medidas (cuestionarios validados y situaciones dentro del juego) se planteó precisamente para mitigar estos sesgos.

En tercer lugar, a pesar de que el tamaño muestral obtenido en Portugal es considerable, la generalización de los resultados a otras áreas geográficas podría ser limitada.

Por último, aunque se incluyó una amplia variedad de variables, no se contemplaron otros factores estructurales o psicológicos adicionales que podrían enriquecer futuros análisis y ofrecer una comprensión más completa de los riesgos digitales en la adolescencia.

VI. CONCLUSIÓN

Los resultados de este estudio exploratorio demuestran que el ciberacoso, el phishing, el online grooming y la exposición a noticias falsas constituyen amenazas generalizadas e interconectadas que afectan a los menores. Incluso en un entorno escolar controlado, muchos participantes mostraron conductas de riesgo o vulnerabilidad, lo que indica una falta de preparación en línea y apoyo adecuados. La metodología innovadora basada en el videojuego permitió observar directamente la toma de decisiones en escenarios realistas, aportando información y patrones difícilmente observados en cuestionarios tradicionales.

Uno de los hallazgos centrales del estudio es el solapamiento significativo de los factores de riesgo entre las cuatro amenazas cibernéticas. Variables como el tiempo de uso de Internet, la comunicación familiar deficiente, la baja autoestima, el escaso apoyo social y la divulgación de información personal aparecieron de forma reiterada como predictores de vulnerabilidad. Esta convergencia sugiere que los riesgos en línea comparten mecanismos de carácter evolutivo, emocional y contextual. Además, la impulsividad indicó que los adolescentes tomaron decisiones rápidas sin evaluar las posibles consecuencias. Del mismo modo, la fuerte asociación entre la información personal compartida en línea y tanto el online grooming como el phishing subraya hasta qué punto los agresores explotan la huella digital de los menores.

Otra conclusión relevante se refiere a la edad. Mientras que los riesgos de ciberacoso y online grooming alcanzan su punto máximo durante la adolescencia temprana, la vulnerabilidad frente al phishing y las noticias falsas no disminuye con la edad, lo que indica que estas competencias no se adquieren de forma natural. La persistencia de estas vulnerabilidades a lo largo de las distintas edades refuerza la necesidad de una enseñanza explícita orientada a reconocer señales de diseño manipulativo, estrategias de persuasión emocional y las tácticas engañosas propias del fraude y la desinformación.

Finalmente, los resultados de este trabajo subrayan la necesidad de diseñar programas de prevención que integren competencias emocionales, cognitivas y digitales. Las intervenciones eficaces deben abordar no solo las habilidades técnicas, sino también las necesidades psicológicas y los entornos

sociales que configuran el comportamiento en línea de los adolescentes. El programa “Missão Cibersegura” constituye una base sólida para avanzar en este objetivo, ya que ofrece evidencias que pueden orientar futuras investigaciones, informar el desarrollo de políticas públicas y apoyar la formación de ciudadanos digitales resilientes y con pensamiento crítico.

AGRADECIMIENTOS

Este proyecto de investigación ha sido posible gracias a la concesión de una beca estratégica por parte del Instituto de Investigación Tecnológica (IIT), como parte de la Universidad Pontificia de Comillas. Parte del trabajo también ha sido posible gracias a la financiación recibida por European Anti-Cybercrime Technology Development Association (EACT-DA) para Tools4LEAs (nº 101136295), a través del proyecto “National plan for the implementation of RAYUELA project in Portugal” y del proyecto PID2022-140217NB-I00, financiado por MCIN/AEI/10.13039/501100011033 y por “ERDF/EU A way of making Europe”.

REFERENCIAS

- [1] Bokolo, B. G., and Liu, Q.: “Artificial Intelligence in Social Media Forensics: A Comprehensive Survey and Analysis”, en *Electronics*, vol. 13, n. 9, pp. 1671, 2024, doi:10.3390/electronics13091671.
- [2] Wolbers, H., Cubitt, T., and Cahill, M. J.: “Artificial intelligence and child sexual abuse: A rapid evidence assessment”, en *Trends and Issues in Crime and Criminal Justice*, n. 711, pp. 1-18, 2025, doi: 10.3316/informit.T2025013000012501673788879
- [3] Franklin-Paddock, B., Platow, M.J. and Ryan, M.K.: “From Privilege to Threat: Unraveling Psychological Pathways to the Manosphere”, en *Archives of Sexual Behavior*, vol. 54, n. 4, pp. 1325–1340, 2025, doi: 10.1007/s10508-025-03114-5.
- [4] Slonje, R., and Smith, P. K.: “Cyberbullying: Another main type of bullying?”, en *Scandinavian journal of psychology*, vol. 49, n. 2, pp. 147-154, 2008, doi: 10.1111/j.1467-9450.2007.00611.x.
- [5] Waasdorp, T. E., and Bradshaw, C. P.: “The overlap between cyberbullying and traditional bullying”, en *Journal of Adolescent Health*, vol. 56, n. 5, pp. 483–488, 2015, doi: 10.1016/j.jadohealth.2014.12.002.
- [6] Nicholson, J., Javed, Y., Dixon, M., Coventry, L., Ajayi, O. D., and Anderson, P.: “Investigating teenagers’ ability to detect phishing messages”, en *2020 IEEE European Symposium on Security and Privacy Workshops (EuroS&PW)*, pp. 140-149, 2020, September. IEEE.
- [7] Craven, S., Brown, S., and Gilchrist, E.: “Sexual grooming of children: Review of literature and theoretical considerations”, en *Journal of sexual aggression*, vol. 12, n. 3, pp. 287-299, 2006.
- [8] Jeglic, E. L., Winters, G. M., and Johnson, B. N.: “Identification of red flag child sexual grooming behaviors”, en *Child Abuse & Neglect*, vol. 136, pp. 105998, 2023.
- [9] Molina-Cañabate, J. P., González-Esteban, J. L., and López-Rico, C. M.: “Children and fake news: Media literacy and digital education in the age of disinformation”, en *Education Sciences*, vol. 13, n. 8, pp. 763, 2023, doi: 10.3390/educsci13080763.
- [10] Kowalski, R. M., Limber, S. P., and McCord, A.: “A developmental approach to cyberbullying: Prevalence, consequences, and risk factors”, en *Journal of Youth and Adolescence*, vol. 48, n. 9, pp. 1767–1781, 2019, doi: 10.1007/s10964-019-01099-4.
- [11] Runions, K. C., Bak, M., and Shaw, T.: “Cyberbullying perpetration and victimization: The role of social-emotional competence and moral disengagement”, en *Aggressive Behavior*, vol. 47, n. 5, pp. 530–541, 2021, doi: 10.1002/ab.21959.
- [12] Algarni, A., Xu, Y., and Chan, T.: “An empirical study on the susceptibility to social engineering in social networking sites: The case of phishing”, en *Information & Computer Security*, vol. 23, n. 4, pp. 367–388, 2015, doi: 10.1108/ICS-05-2014-0029.
- [13] Jagatic, T. N., Johnson, N. A., Jakobsson, M., and Menczer, F.: “Social phishing”, en *Communications of the ACM*, vol. 50, n. 10, pp. 94-100, 2007.
- [14] Gámez-Guadix, M., De Santisteban, P., and Resett, S.: “Sexting among Spanish adolescents: Prevalence and association with sexual grooming and cyberbullying victimization”, en *Computers in Human Behavior*, vol. 120, pp. 106761, 2021, doi: 10.1016/j.chb.2021.106761.
- [15] Reneses, M., Riberas-Gutiérrez, M., and Bueno-Guerra, N.: ““He flattered me”. A comprehensive look into online grooming risk factors: Merging voices of victims, offenders and experts through in-depth interviews”, en *Cyberpsychology: Journal of Psychosocial Research on Cyberspace*, vol. 18, n. 4, 2024.
- [16] Whittle, H., Hamilton-Giachritsis, C., Beech, A., and Collings, G.: “A review of online grooming: Characteristics and concerns”, en *Aggression and Violent Behavior*, vol. 19, n. 1, pp. 62–70, 2014, doi: 10.1016/j.avb.2013.11.007.
- [17] Pennycook, G., and Rand, D. G.: “Lazy, not biased: Susceptibility to partisan fake news is better explained by lack of reasoning than by motivated reasoning”, en *Cognition*, vol. 188, pp. 39–50, 2019, doi: 10.1016/j.cognition.2018.06.011.
- [18] Reneses, M., Riberas-Gutiérrez, M., and Bueno-Guerra, N.: “Who shares fake news? The consumption and distribution of information among adolescents and its relationship to hate speech”, en *Revista de educación*, n. 406, pp. 265-291, 2024.
- [19] Riberas-Gutiérrez, M., Reneses, M., Gómez-Dorado, A., Serranos-Minguela, L., and Bueno-Guerra, N.: “Online grooming: factores de riesgo y modus operandi a partir de un análisis de sentencias españolas”, en *Anuario de Psicología Jurídica*, vol. 34, n. 1, pp. 119-131, 2024.
- [20] Reneses, M., Riberas-Gutiérrez, M., and Bueno-Guerra, N.: ““It’s just a joke”: gender, sexuality and trivialisation in adolescent online violence such as cyberhate, cyberbullying, and online grooming”, en *Humanities and Social Sciences Communications*, vol. 12, n. 1, pp. 1-14, 2025.
- [21] Reneses, M., Parder, M. L., Riberas-Gutiérrez, M., and Bueno-Guerra, N.: “Cyberbullying and cyberhate as an overlapping phenomenon among adolescents in Estonia and Spain: Cross-cultural differences and common risk factors”, en *Children and Youth Services Review*, vol. 172, pp. 108285, 2025.
- [22] Shrestha, N.: “Factor analysis as a tool for survey analysis”, en *American journal of Applied Mathematics and statistics*, vol. 9, n. 1, pp. 4-11, 2021.
- [23] Marengo, D., and Settanni, M.: “Examining the postdictive validity of self-report Big Five personality traits with objective recordings of online behaviors: a ten-year retrospective study using Facebook Page Likes”, en *Heliyon*, vol. 10, n. 12, 2024.
- [24] Herrero-Diz, P., Conde-Jiménez, J., and Reyes de Cózar, S.: “Teens’ motivations to spread fake news on WhatsApp”, en *Social Media+ Society*, vol. 6, n. 3, pp. 1–14, 2020, doi: 10.1177/2056305120942879.
- [25] McGrew, S., Ortega, T., Breakstone, J., and Wineburg, S.: “The Challenge That’s Bigger than Fake News: Civic Reasoning in a Social Media Environment”, en *American Educator*, vol. 41, n. 3, pp. 4–9, 2017.
- [26] Walrave, M., Vanwesenbeeck, I., and Heirman, W.: “Connecting and protecting? Comparing predictors of self-disclosure and privacy settings use between adolescents and adults”, en *Cyberpsychology: Journal of Psychosocial Research on Cyberspace*, vol. 6, n. 1, 2012.
- [27] Ribeiro, L., Guedes, I. S., and Cardoso, C. S.: “Which factors predict susceptibility to phishing? An empirical study”, en *Computers & Security*, vol. 136, pp. 103558, 2024.
- [28] Kavvadias, A., and Kotsilieris, T.: “Understanding the role of demographic and psychological factors in users’ susceptibility to phishing emails: A review”, en *Applied Sciences*, vol. 15, n. 4, pp. 2236, 2025.
- [29] Kowalski, R. M., Giumetti, G. W., Schroeder, A. N., and Lattanner, M. R.: “Bullying in the digital age: a critical review and meta-analysis of cyberbullying research among youth”, en *Psychological bulletin*, vol. 140, n. 4, pp. 1073, 2014.
- [30] Akter, M., Godfrey, A. J., Kropczynski, J., Lipford, H. R., and Wisniewski, P. J.: “From parental control to joint family oversight: Can parents and teens manage mobile online safety and privacy as equals?”, en *Proceedings of the ACM on Human-Computer Interaction*, vol. 6, n. CSCW1, pp. 1-28, 2022.
- [31] Dittus, P. J.: “Parental monitoring and risk behaviors and experiences among high school students—Youth Risk Behavior Survey, United States, 2021”, en *MMWR supplements*, vol. 72, 2023.
- [32] Álvarez-García, D., García, T., and Betts, L.: “Anxiety and self-esteem as causes and consequences of cyber-victimization in preadolescence: a longitudinal study”, en *European Journal of Psychology Applied to Legal Context*, vol. 7, n. 1, pp. 1-9, 2025.
- [33] Jerrim, J.: “Who Responds to Phishing Emails? An International Investigation of 15-Year-;? a3b2 show [nbs];?;Olds;? a3b2 show [nbs];?;Using PISA Data”, en *British Journal of Educational Studies*, vol. 71, n. 6, pp. 701-724, 2023.

Innovación en la Enseñanza de la Gestión de la Ciberseguridad en Estudios de Grado Universitario

Marc Ruiz

Universitat Politècnica de Catalunya (UPC)
Jordi Girona 31, 08034 – Barcelona (España)
marc.ruiz-ramirez@upc.edu

Fernando Agraz

Universitat Politècnica de Catalunya (UPC)
Jordi Girona 31, 08034 – Barcelona (España)
fernando.agraz@upc.edu

Resumen- La adquisición de conocimiento en el ámbito de la gestión de la ciberseguridad es una pieza fundamental en la formación de jóvenes ingenieros capaces de afrontar los retos que demandan la industria y la sociedad en cuanto a seguridad informática se refiere. No obstante, la naturaleza de la materia suele generar contenidos densos y poco atractivos para el estudiantado, lo que resulta poco motivador desde un punto de vista académico. Este artículo presenta una metodología docente innovadora, actualmente en aplicación, para la enseñanza de Gestión de la Ciberseguridad en estudios de grado de la Universitat Politècnica de Catalunya. Este nuevo modelo, basado en pilares como contenidos fundamentales, materias vivas y actuales, y el aprendizaje basado en casos prácticos, ha resultado en un aumento de la matriculación del 60 % y en una satisfacción del alumnado superior al promedio de la universidad.

Index Terms- Innovación Docente, Gestión de la Ciberseguridad, Grado Universitario

Tipo de contribución: Formación e innovación educativa

I. INTRODUCCIÓN

El panorama actual del ámbito de Tecnologías de la Información y Comunicaciones (TIC) está marcado por un auge sin precedentes en el interés por la ciberseguridad. Este fenómeno, impulsado por una creciente demanda de profesionales en el mercado laboral, ha provocado una expansión significativa de la oferta académica en el ámbito universitario. Tradicionalmente, la especialización en esta materia se ha articulado a través de programas de posgrado y máster, diseñados para perfiles técnicos con experiencia previa en ciberseguridad que buscan alcanzar un nivel avanzado y consolidar su carrera profesional [1].

Dentro de esta formación especializada, la gestión de la ciberseguridad ocupa un lugar central. Entendida como el conjunto de procesos, políticas y controles destinados a proteger los activos de información y garantizar la resiliencia organizativa, la gestión es una pieza crítica para cualquier experto en ciberseguridad [2]. De hecho, parte del alumnado de posgrado orienta su aprendizaje hacia la obtención de capacidades que permitan alcanzar certificaciones de prestigio internacional, como el CISM (Certified Information Security Manager) de ISACA, que avalan un dominio estratégico y de gobierno sobre la seguridad [3].

No obstante, el interés por la ciberseguridad ya no se confina exclusivamente a profesionales en activo o estudiantes de máster. En los últimos años, se ha detectado una demanda creciente en los estudios de grado. Si bien las asignaturas técnicas orientadas a la adquisición de conocimientos elementales y habilidades prácticas gozan de gran popularidad, a menudo adolecen de una carencia crítica: la falta de una

perspectiva global y contextual de la ciberseguridad. Al omitir la gestión en las etapas iniciales de la formación, los egresados de grado pueden presentar un déficit de competencias que limita su visión estratégica del riesgo y la seguridad.

Bajo esta premisa, resulta fundamental integrar cursos básicos de gestión de la ciberseguridad en el currículo de grado. Estos deben proporcionar no solo conceptos clave y una base sólida, sino también un entendimiento claro de las oportunidades de desarrollo laboral que ofrece este campo. Sin embargo, este traslado de conocimientos presenta un reto pedagógico: el alumnado de grado es hoy más heterogéneo que nunca y, a diferencia del perfil de máster, carece habitualmente de experiencia previa en el mundo TIC. Por ello, el enfoque docente y los objetivos deben diferenciarse sustancialmente del modelo de posgrado, adaptándose a un perfil que todavía no ha iniciado su trayectoria profesional.

En este artículo, presentamos el proyecto de innovación docente de la asignatura Gestión de la Ciberseguridad (GCS) que se imparte en la Facultad de Informática de Barcelona (FIB) de la Universidad Politècnica de Catalunya (UPC). Esta asignatura se oferta como optativa desde 2018 a estudiantes de grado de la FIB. El proyecto, que lleva desarrollándose y aplicación desde el curso 2022/23, pretende ofrecer un contenido y una metodología más apropiada a las necesidades, objetivos docentes, y conocimientos del perfil de estudiante de grado universitario de hoy en día.

El resto del artículo se organiza de la siguiente manera: la sección II presenta un análisis crítico del punto de partida y la contextualización de la asignatura antes de la reforma, identificando las debilidades del modelo tradicional y las necesidades del estudiantado actual. La sección III describe la propuesta docente innovadora, articulada sobre tres pilares: contenidos fundamentales adaptados al nivel de grado universitario, materias vivas y en constante actualización, y una metodología basada en casos prácticos. A continuación, la sección IV detalla la implementación de un caso práctico específico en el que los alumnos asumen el rol de analistas de ciberseguridad junior en un entorno laboral simulado. La sección V expone las evidencias recogidas hasta la fecha tras la aplicación del proyecto, analizando la evolución de la matriculación, el conocimiento adquirido, y el incremento en la satisfacción del alumnado. Finalmente, la sección VI presenta las conclusiones derivadas de esta experiencia de innovación educativa.

II. ANÁLISIS Y CONTEXTUALIZACIÓN

Esta sección presenta los aspectos más relevantes de la guía docente de la asignatura GCS antes de la aplicación de la metodología innovadora realizada en este proyecto. La

información referente a este punto de partida (curso 2021/2022) puede contrastarse y consultarse en más detalle en el repositorio histórico de la asignatura [4]. A continuación, se realiza un análisis crítico orientado a identificar los aspectos fuertes y a mejorar de la asignatura, que sirven para motivar y guiar el desarrollo de la nueva metodología docente propuesta.

A. Punto de partida

La asignatura GCS es una asignatura optativa de 6 créditos ECTS de cuarto año de grado, que tiene por objetivo complementar los conocimientos de ciberseguridad de los alumnos y fomentar la colaboración entre ellos en la búsqueda de información sobre diferentes temas relacionados con la seguridad informática, como deberán hacer en su actividad profesional, para defender los activos de las empresas a las que trabajen. Los objetivos principales de la asignatura son:

- 1) Conocer el mercado de la ciberseguridad.
- 2) Identificar los diferentes problemas de ciberseguridad de las empresas y conocer las soluciones aplicables.
- 3) Trabajar en equipo para redactar informes y hacer presentaciones en clase

Estos objetivos están orientados a la obtención de diversas competencias técnicas y transversales, entre las que destacan: *i)* utilizar de forma apropiada teorías, procedimientos y herramientas en el desarrollo profesional en el ámbito TIC, asegurando su fiabilidad, su seguridad y su calidad, conforme a principios éticos y a la legislación y la normativa vigente; *ii)* demostrar conocimiento y comprensión del contexto organizativo, económico y legal en el que desarrolla su trabajo, incluyendo la normativa y la regulación de la informática en los ámbitos nacional, europeo e internacional; *iii)* evaluar y seleccionar plataformas de producción hardware y software en términos de seguridad y fiabilidad; *iv)* gestionar la adquisición, la estructuración, el análisis y la visualización de datos e información del ámbito TIC y valorar de forma crítica los resultados de esta gestión.

El contenido teórico de la asignatura se divide en lecciones organizadas en tres bloques diferenciados:

- **Bloque 1 - prevención y respuesta a incidentes de ciberseguridad:** monitorización, obtención de información, ciber-inteligencia, respuesta a incidentes, seguridad de la computación en la nube, implementación.
- **Bloque 2 - ciberseguridad y tecnologías emergentes:** federación de identidades, blockchain, Internet de las cosas (IoT), sistemas de control industrial (ICS), computación cuántica.
- **Bloque 3: Gobernanza de la ciberseguridad:** gestión de políticas y prácticas empresariales, privacidad y robo de identidad en las redes sociales, comercio electrónico seguro, economía del cibercrimen, normativa y legislación.

La asignatura se imparte en base a la organización de un modelo docente que se replica para cada uno de los temas propuestos:

- 1) Introducción de los problemas de ciberseguridad y soluciones existentes por parte del profesor y en algunos casos por un experto invitado.
- 2) Presentación complementaria de un grupo de alumnos sobre un aspecto concreto relacionado con el tema.
- 3) Debate en clase sobre publicaciones en los que se explican incidentes o tendencias en las herramientas o

estrategias específicas para abordar los problemas de ciberseguridad relacionados con este tema.

Finalmente, la evaluación se realiza mediante varios controles de tipo test de múltiple respuesta, informes escritos, y presentaciones orales.

B. Análisis crítico

Basado en la experiencia propia en la impartición de la asignatura, se ha realizado un análisis crítico detallado en búsqueda de una nueva metodología docente. La Fig. 1 muestra un resumen gráfico de dicho análisis, cuyos detalles se proporcionan a continuación:

- La asignatura tiene una gran demanda entre los estudiantes de grado, ya que la temática de la ciberseguridad genera mucho interés y, en cambio, la oferta de asignaturas de grado relacionadas con la ciberseguridad es, a día de hoy, aún escasa.
- Este interés es mostrado no solamente por estudiantes del grado de ingeniería informática (GEI), sino por estudiantes de otros grados impartidos en la FIB, como son el grado en ciencia e ingeniería de datos (GCED), y el grado en inteligencia artificial (GIA). En estos casos, el conocimiento de aspectos fundamentales relacionados con la ingeniería informática (arquitectura de computadores, computación, redes) son pobres.
- Debido a la heterogeneidad de grados y perfiles (especialidades) de los alumnos que eligen esta optativa, el bagaje de los alumnos es muy diverso. No obstante, en general, el nivel de conocimientos previos acerca de ciberseguridad es significativamente bajo. Eso hace que el tipo y profundidad del contenido, más pensado como una extensión sobre un conocimiento previo en ciberseguridad, se aleje mucho del bagaje real del estudiantado.
- Por ello, y a pesar del interés que despierta en el periodo de matrícula, la asistencia a clases es muy baja. Algunos motivos que hay detrás de esta tendencia son: *i)* un rechazo cada vez mayor a las sesiones magistrales de teoría (tendencia que se puede apreciar también en otras asignaturas); *ii)* una metodología de evaluación que no requiere de una asistencia constante a clases; *iii)* una falta de interactividad y participación genere una dinámica favorable para su aprendizaje y evolución en la asignatura.




Fig. 1. Análisis crítico del punto de partida de GCS

- El contenido de algunas partes está desactualizado y en algunos casos, obsoleto. Además, se obvian temas que a día de hoy son cruciales, p. ej., la inteligencia artificial (IA) como tecnología emergente, y que generaría mucho más interés.
- En general, los recursos disponibles (transparencias) contienen mucho material y un tanto desorganizado, con lo que el seguimiento de la materia a partir de esos recursos se hace áspera.
- Finalmente, el uso de agentes de IA generativa tales como ChatGPT¹ y otras herramientas similares hacen que la realización de los trabajos de investigación se lleve a cabo sin ningún tipo de profundidad e interés por los estudiantes, más allá de obtener la nota más alta posible que les permita superar la asignatura e incluso, obtener una buena nota final.

En vistas de este análisis, se detectan las siguientes necesidades de mejora, con el fin de producir una asignatura adecuada al nivel de grado universitario:

- 1) Reenfocar parte de los contenidos de la asignatura para proveer de una base sólida en aspectos básicos de la ciberseguridad que los estudiantes generalmente no tienen al matricularse. Eso permite poder enfocarse en temas elementales de la gestión de la ciberseguridad, más que en proveer casos de uso avanzados que queden fuera del alcance e interés de los alumnos.
- 2) Implementar sesiones prácticas que permitan una mayor interactividad y seguimiento continuado por parte del alumno, lo que haga aumentar la presencialidad y el interés por la asignatura. Explotar una variedad de recursos didácticos que permitan aplicar satisfactoriamente esta dinámica positiva.
- 3) Generar un conocimiento e interés por la ciberseguridad que no solamente tenga continuidad en el terreno laboral de los estudiantes egresados, sino que abra la posibilidad de continuar formándose en este campo mediante la realización de estudios avanzados, p. ej., el Máster en Ciberseguridad de la UPC.

III. PROPUESTA DOCENTE INNOVADORA

La Fig. 2 muestra la visión general de la propuesta de innovación docente que se está aplicando progresivamente en GCS desde el curso 2022/23, como respuesta a las necesidades de cambio identificadas en el plan de estudios original de la asignatura y que han sido identificadas en la sección anterior. El plan de estudios de la asignatura en la actualidad (curso 2025/26) puede consultarse en la guía docente oficial [5].

Esta metodología, pues, se nutre inicialmente del plan de estudios original descrito en la sección II.A y del análisis crítico detallado en la sección II.B. Además, de forma constante y continua, la asignatura se va actualizando, adaptando, y mejorando a partir del estado actual de la ciberseguridad (p. ej. a partir de referencias como [6]) y de las tendencias educativas en innovación docente.

La nueva propuesta educativa de GCS se construye sobre 3 pilares esenciales, que son:

- *Contenidos fundamentales* de Gestión de Ciberseguridad: añadiendo conceptos básicos




Fig. 2. Visión general de la nueva propuesta metodológica

elementales y suprimiendo conceptos avanzados fuera de lugar, logramos adaptar la asignatura a un perfil de estudiante de grado. Estos cambios en el temario se realizan sin perder la perspectiva de ofrecer una visión global sobre la gestión de la ciberseguridad.

- *Materias vivas*: reorganización de los contenidos teóricos con el fin de ofrecer contenido actualizado y adaptable a los cambios tecnológicos, socio-económicos y geo-políticos que impactan en la gestión de la ciberseguridad. Inclusión de materias novedosas como son el uso de la IA, redes avanzadas (5G y más allá), o sistemas de computación basados en microservicios, por mencionar algunos.
- *Casos prácticos*: reorganización de los contenidos en clases teóricas y prácticas, estas últimas basadas en la realización de ejercicios y prácticas dentro de contextos más amplios (los llamados casos prácticos). Estas prácticas y ejercicios se realizan generalmente en grupos pequeños de perfiles heterogéneos para fomentar la participación multidisciplinar y el trabajo activo durante todo el curso.

Estos cambios pretenden dotar a los estudiantes de contenidos y habilidades prácticas útiles para que puedan discernir si el mundo de la ciberseguridad en general, y de la gestión en particular, les resulta atractivo y motivador para continuar con estudios académicos más avanzados, p. ej., matriculándose al Master de Ciberseguridad una vez finalicen los estudios de grado [1]. Mediante la combinación de clases teóricas y ejercicios organizados en casos prácticos, se pretende que los estudiantes sostengan la motivación y el interés por la asignatura durante todo el curso. Como consecuencia de esta motivación sostenida, se pretende que el estudiantado asista en su mayoría a las sesiones teóricas y prácticas, y que, además, participe proactivamente en ellas. Respecto a esta participación, un aspecto fundamental es la retroalimentación que puedan ofrecer como usuarios de la asignatura, y que el profesorado recoge de forma metódica (encuestas periódicas) y esporádica (consultas y reuniones con estudiantes). Esta retroalimentación es básica para ofrecer una

¹ <https://chatgpt.com/>

metodología que, sin desvirtuar los objetivos principales de la asignatura, se adapte lo mejor posible a las necesidades y especificidades del estudiantado.

Como resultado de las innovaciones propuestas, los objetivos originales de la asignatura se han reorientado del siguiente modo

- 1) Conocer conceptos básicos sobre ciberseguridad, cibercrimen, y análisis de riesgos y vulnerabilidades.
- 2) Identificar diferentes problemas y soluciones en tecnologías actuales, emergentes y disruptivas.
- 3) Trabajar en equipo para la realización de las prácticas.
- 4) Realizar satisfactoriamente prácticas guiadas sobre ciberseguridad.

Aunque las competencias, en general, se mantienen parecidas a las del plan de estudios original, se han eliminado aquellas relacionadas con contenidos obsoletos y se han añadido aquellas competencias que se alcanzan tanto con la adquisición de los nuevos conocimientos, como con la realización de las prácticas guiadas y casos prácticos.

El contenido teórico de la asignatura se compacta ahora en dos grandes bloques, orientados a alcanzar satisfactoriamente los objetivos 1 y 2 de la asignatura:

- *Bloque 1 - Conceptos Generales:* conceptos introductorios sobre ciberseguridad (CI&A), introducción a las organizaciones y legislación / regulación de la ciberseguridad, seguridad básica en sistemas TIC, recogida de información, monitorización, respuesta a incidentes, gestión de la identidad digital, educación y aspectos éticos,
- *Bloque 2 - Tecnologías actuales, emergentes, y disruptivas:* arquitecturas basadas en microservicios, entornos IoT e industriales, redes de comunicaciones 5G y más allá, IA, blockchain, distribución de claves cuánticas.

Los objetivos 3 y 4 se consiguen mediante la realización de casos prácticos que contienen laboratorios guiados y ejercicios que se realizan en paralelo con las sesiones de teoría. Típicamente, cada semana de curso se dedican 2 horas a clases de teoría y 2 horas a los casos prácticos. Cada caso práctico se alarga durante 4 o 5 semanas, y está compuesto por distintas actividades y entregables. Los casos prácticos que se proponen en la actualidad son tres:

- *Caso 1 - Analistas de Ciberseguridad Junior:* los estudiantes simulan ser miembros de un equipo de respuesta a incidentes y realizan tareas de gestión relacionadas con su perfil laboral. Este caso práctico se detalla en la sección IV de este artículo.
- *Caso 2 – Seguridad en Sistemas Virtualizados:* mediante la ejecución de ejercicios guiados en un entorno virtualizado, se adquieren conocimientos prácticos sobre recopilación de información, gestión de vulnerabilidades, y el proceso de respuesta a incidentes. Los ejercicios prácticos se combinan y relacionan con la exploración de documentación sobre legislación y normativa vigente, p. ej., la directiva NIS-2 [7].
- *Caso 3 – Entornos IoT con IA y blockchain:* se propone un escenario práctico que combina dispositivos IoT (virtualizados), modelos de IA, y blockchain con el fin de crear un entorno de tecnologías emergentes que permita realizar ejercicios concretos (p. ej., explotación de vulnerabilidades de un modelo de IA basado en

redes neuronales). Del mismo modo que en el caso 2, se relaciona la actividad práctica con la normativa actual, así como con la perspectiva emergente en gobernanza, p. ej., la regulación 2023/2854 (Data Act) de la unión europea [8].

Finalmente, y no por ello menos importante, la evaluación de la asignatura también se ha adaptado. El peso de los exámenes de teoría y de los casos prácticos es equivalente, lo que dota de importancia a los segundos. Cada caso de uso se divide en diversas entregas (de 1 a 3) de distinto tipo: presentaciones orales, debates en clase, informes detallados, material infográfico, y código fuente.

IV. CASO PRÁCTICO: ANALISTA DE SEGURIDAD JUNIOR

Esta sección presenta en detalle el caso práctico 1 enumerado en la sección anterior, donde los estudiantes simulan formar parte de un equipo de respuesta a incidentes de una organización a nivel de analistas de ciberseguridad junior. La descripción corresponde a la versión del caso que se está llevando a cabo durante el vigente curso 2025/26.

A. Enunciado, objetivos, y metodología

La actividad planteada se estructura bajo la metodología de aprendizaje basado en casos, diseñada para que el estudiantado integre conocimientos técnicos en un entorno laboral simulado. El ejercicio sitúa al alumno en el rol de analista de ciberseguridad junior dentro una organización específica, ya sea una empresa o una institución gubernamental. Los ejemplos puestos en práctica en clase hasta la fecha han considerado diversos ejemplos, como son: el Departamento de Educación de una comunidad autónoma, el Ministerio de Transporte de un estado miembro de la Unión Europea, y una empresa proveedora de servicios de ciberseguridad para entornos industriales e infraestructuras críticas. El núcleo del ejercicio consiste en la transferencia de información técnica, extraída de diversos informes de alcance global y accesibles públicamente, hacia productos operativos que respondan a necesidades organizativas reales.

El esquema representado en la Fig. 3 muestra el flujo de trabajo del ejercicio propuesto. Los docentes de la asignatura, en el rol de directores/coordinadores del equipo de respuesta a incidentes de la organización (CSIRT), confeccionan los grupos de trabajo que formarán los equipos de analistas junior (etiquetado con el número 1 en la Fig. 3). En este punto, se fomenta la multidisciplinariedad, teniendo en cuenta la variedad de perfiles presentes en el aula.

Los analistas deberán hacer una primera exploración de la literatura disponible con el fin de adquirir una base previa para la realización de actividades más avanzadas (2). Para ello, se les sugiere una serie de referencias básicas como son los enlaces a las páginas web del Instituto Nacional de Ciberseguridad (INCIBE), la Agencia de la Unión Europea para la Ciberseguridad (ENISA), y la base de conocimiento MITRE ATT&CK. Después de un periodo de exploración libre, se les plantea una encuesta para evaluar el grado de conocimiento previo y adquirido sobre el material y fuentes consultadas (3).

Pasada esta fase inicial de la actividad, se les proporcionan a los equipos de analistas instrucciones para que busquen documentos e informes específicos sobre los que formular las actividades más complejas (4). Algunos de los informes




Fig. 3. Esquema del ejercicio propuesto

utilizados hasta la fecha son: i) ENISA Threat Landscape (ETL) [6], ii) base de conocimiento MITRE ATT&CK [9], iii) análisis de los 10 principales riesgos de ciberseguridad de Open Worldwide Application Security Project (OWASP) [10]. En el caso de documentos largos y densos, como el ETL, se les proporciona una guía de lectura, con ejercicios y preguntas a resolver, con el fin de acotar los contenidos y evitar un exceso de sobreinformación poco útil.

Llegados a este punto, se les plantea a los equipos la realización de dos actividades avanzadas:

- *Comunicación Estratégica y Gestión de la Desinformación* (5-7): ante un escenario donde la dirección general de la organización (CEO) se encuentra influenciada por narrativas alarmistas sobre el "hackeo con IA" y el "hacktivismo", se solicita el desarrollo de dos materiales:
 - Infografía Ejecutiva: Un recurso visual de una página destinado a ser mostrado y explicado en una hipotética reunión con el director general de la organización.
 - Guion Explicativo de la Infografía: se asume que dicha reunión se lleva a cabo con periodicidad mensual, donde los distintos responsables y coordinadores (incluidos los del CSIRT) asisten y tratan temas agendados con el CEO. Por lo tanto, es imprescindible generar un documento de texto (de media a una página) que acompañe a la infografía, y que sirva para que el responsable del CSIRT pueda preparar el contenido de la reunión.

El objetivo pedagógico de esta actividad es que el estudiante aprenda a distinguir el ruido mediático del peligro real, utilizando la evidencia del informe ETL para desmitificar el uso de la IA en ataques cibernéticos y reenfocar la atención hacia vulnerabilidades críticas y tiempos de respuesta a incidentes específicos de la organización.

- *Evaluación de Vulnerabilidades en el Factor Humano* (8-10): Para abordar la falta de concienciación en seguridad del personal de la organización de los distintos departamentos y secciones, el equipo de analistas junior debe diseñar una aplicación de evaluación diagnóstica. Así, se les propone diseñar una aplicación que permita elaborar preguntas de tipo test

(binarias o de opción múltiple) centradas en vectores de ataque actuales que afecten directamente a las vulnerabilidades personales, como son: el "phishing" asistido por IA, malas prácticas en el uso de mecanismos de autenticación, y consciencia sobre tácticas de ingeniería social para el recabado de información personal y/o técnica sensible.

Para el diseño de dicha aplicación, se les propone revisar en profundidad juegos en línea que traten diversos temas de ciberseguridad de forma amena, p. ej., los juegos de concienciación sobre seguridad del Centro para Desarrollo de la Excelencia en Seguridad (CSDE) del gobierno de los Estados Unidos de América², con el fin de encontrar ideas y/o posibles enlaces a incluir en sus aplicaciones.

El producto final deberá ir acompañado de una documentación técnica, identificando las vulnerabilidades específicas que pretende detectar la aplicación y su referencia exacta en la documentación proporcionada (ENISA ETL, MITRE ATT&CK, y top-10 OWASP).

B. Competencias técnicas, analíticas, y transversales

Las principales competencias técnicas y de conocimiento de este caso práctico son:

- Comprender el ecosistema de las amenazas de ciberseguridad: Familiarizarse con el informe ENISA ETL como referente anual del estado de la ciberseguridad.
- Identificar elementos críticos de los ataques: Reconocer las principales amenazas, tendencias, actores y técnicas de ataque, así como sus motivaciones e impactos.
- Evaluar medidas de mitigación: Describir y aplicar las medidas de defensa y mitigación pertinentes para las amenazas identificadas.
- Analizar el factor humano: Detectar debilidades en los empleados relacionadas con la ingeniería social, el phishing asistido por IA y la higiene en la autenticación.

Por lo que respecta a competencias analíticas y de pensamiento crítico, estas son las más relevantes:

- Sintetizar información compleja: Desarrollar la capacidad de procesar y resumir datos provenientes de

² <https://www.cdse.edu/Training/Security-Awareness-Games/>

diferentes informes técnicos para extraer conclusiones operativas.

- Discernir entre riesgo real y narrativa mediática: Aprender a distinguir el ruido o la exageración mediática de los peligros reales basados en datos y experiencia reportada.
- Desmitificar tendencias tecnológicas: Actuar como un "cazador de mitos" ante visiones distorsionadas sobre, p. ej., el uso de la IA en el hackeo.
- Priorizar vulnerabilidades estratégicas: Reenfocar la atención hacia aspectos fundamentales como los tiempos de respuesta ante incidentes y la organización de la defensa, más allá de las tendencias de moda.

Finalmente, las competencias transversales y profesionales que se trabajan en este ejercicio son:

- Simular roles profesionales: Adaptarse al papel de un analista de ciberseguridad junior en una institución determinada.
- Comunicación multinivel: Traducir información técnica compleja en materiales divulgativos (infografías y guiones) aptos para responsables políticos o directivos no técnicos.
- Diseño de herramientas de evaluación: Elaborar cuestionarios de diagnóstico técnico-pedagógico para medir el nivel de concienciación en seguridad de una organización.
- Trabajo colaborativo y gestión de activos: Organizar grupos de trabajo identificando capacidades individuales, roles (representante) y recursos disponibles.

C. Implementación y evaluación

Esta actividad se realiza en paralelo a la realización de las primeras clases de teoría del curso, centradas en conceptos fundamentales de ciberseguridad, seguridad de entornos de computación en la nube, monitorización y recogida de información, y gestión de la respuesta a incidentes. La actividad se desarrolla a lo largo de 5 semanas, distribuidas de la siguiente manera (se incluyen los entregables evaluables y su peso en la nota final de la actividad):

- *Semana 1:* Formación de los equipos de analistas junior, primera exploración de la literatura y encuesta.
- *Semana 2:* Búsqueda y estudio de los documentos de referencia (ETL), lectura guiada y planteamiento inicial de las actividades.
 - Entrega de respuestas a preguntas y ejercicios de la lectura guiada (15%)
- *Semana 3:* Exploración de juegos en línea para la realización de la herramienta de detección de vulnerabilidades.
 - Presentación oral y debate de la exploración de juegos en línea (25%)
- *Semana 4:* Realización de las actividades avanzadas propuestas.
- *Semana 5:* Entrega de las actividades para su evaluación.
 - Infografía Ejecutiva + Guion Explicativo (25%)
 - Aplicación Detección de Vulnerabilidades (35%)

V. EVIDENCIAS

En esta sección se presentan algunas evidencias obtenidas

durante la realización de la actividad descrita en la Sección IV durante el actual curso 2025/2026, así como algunos resultados sobre la evolución de la participación y grado de satisfacción del alumnado desde el curso 2018/2019.

La Fig. 4 muestra los resultados obtenidos en la encuesta realizada en la Semana 1, por lo que respecta al conocimiento previo sobre la existencia de ENISA y de MITRE ATT&CK. Las encuestas han sido realizadas por los 62 alumnos matriculados en el cuatrimestre de primavera del presente curso. Los resultados muestran claramente la evidencia que el alumnado de GCS carece de conocimiento previo sobre organizaciones e iniciativas básicas relacionadas con la gestión de la ciberseguridad, lo que apoya la iniciativa de reformular la asignatura propuesta en este artículo. La Fig. 5 corrobora la evidencia anterior, ya que la inmensa mayoría de los alumnos encuentran que el material proporcionado contiene una cantidad relevante de contenido novedoso. Finalmente, en cuanto al formato y estilo del material proporcionado, la Fig. 6 indica que éste resulta relativamente amigable (entre neutro y atractivo). Por todo esto, podemos concluir que el material propuesto resulta útil y atractivo, siendo muy apropiado para el perfil de estudiante de grado universitario.

Como muestra del tipo de sesiones realizadas, la Fig. 7 muestra la actividad realizada durante la Semana 3, en la que los distintos equipos de analistas junior juegan a varios recursos en línea y los analizan como potenciales herramientas para el entrenamiento en ciberseguridad, lo que les da recursos para preparar la aplicación de detección de vulnerabilidades.




Fig. 4. Encuesta conocimiento previo




Fig. 5. Encuesta contenidos




Fig. 6. Encuesta formato y estilo



Fig. 7. Sesión análisis de juegos online (realizada el día 27/02/2026)

En la fotografía se muestra a varios equipos presentando sus conclusiones al resto de equipos presentes en el aula, después de haber jugado a los juegos durante un tiempo limitado (1 hora por juego). De esta manera, se fomenta la participación entre equipos, ya que cada uno prepara concienzudamente el análisis de uno de los juegos, y atiende a los análisis realizados por los otros equipos sobre otros juegos.

Complementado los resultados anteriores, a continuación, se muestran algunos resultados sobre la evolución de la asignatura en los últimos cursos. En primer lugar, la Fig. 8 muestra la evolución de los alumnos matriculados desde el curso 2022/23. Estos datos provienen del sistema de gestión de los estudios que da soporte a la gestión de procesos académicos de la UPC³. Los datos muestran un incremento del 60% en este último curso, fruto de la apuesta por el incremento de plazas como consecuencia directa del gran interés que suscita la asignatura. Además, la composición de alumnos en cuanto al grado de procedencia está variando. Aunque la proporción de alumnos que cursan el GEI es claramente mayoritaria, el porcentaje de alumnos procedentes de estudios como GCED, GIA, e incluso alumnos de master y Erasmus, está en aumento. En otros términos, la heterogeneidad de perfiles y bagajes en el aula está incrementando a cada curso.

³ <https://prisma-nou.upc.edu/>

Finalmente, la Fig. 9 muestra la evolución de la evaluación que los alumnos realizan de forma voluntaria a través de las encuestas de satisfacción del estudiantado de la UPC. Estos resultados se pueden consultar en abierto en la plataforma de indicadores de docencia de la UPC [11]. Por lo que respecta a la pregunta clave ("en conjunto, estoy satisfecho con la




Fig. 8. Evolución alumnos matriculados




Fig. 9. Resultados Satisfacción Estudiantes

asignatura"), vemos un claro incremento a partir del curso 2022/23, cuando las innovaciones presentadas en este artículo empezaron a ponerse en práctica paulatinamente. Así pues, de unos inicios donde la asignatura tenía valoraciones inferiores al promedio de la universidad, hemos pasado a estar claramente por encima de dicho promedio. Estos resultados permiten concluir que la apuesta por la innovación y la adaptación de la temática de la gestión de la ciberseguridad a un estudiantado de grado universitario está resultando un éxito remarkable.

VI. CONCLUSIONES

La implementación del proyecto de innovación docente de la asignatura de grado universitario GCS impartido en la FIB de la UPC ha demostrado ser una solución eficaz para adaptar la enseñanza de la gestión de la ciberseguridad a un perfil de estudiante de grado diverso y habitualmente sin experiencia profesional previa. Al reestructurar la asignatura sobre pilares esenciales como son contenidos fundamentales, materias vivas actualizadas y el uso intensivo de casos prácticos, se ha logrado transformar un temario tradicionalmente denso en una experiencia de aprendizaje atractiva y alineada con las

demandas tanto académicas (plan de estudio) como laborales (perspectivas de empleo).

Los resultados obtenidos respaldan este cambio de metodología, destacando un incremento del 60% en la matrícula durante el último curso y una mejora sustancial en la satisfacción del alumnado, que ha pasado de valoraciones inferiores al promedio a situarse claramente por encima de la media. Las evidencias muestran que el uso de simulaciones profesionales, como el rol de analista junior y el análisis de informes relevantes como el ENISA ETL y MITRE ATT&CK, ha sido clave para generar un interés genuino y una percepción positiva del aprendizaje.

En conclusión, este enfoque pedagógico no solo dota a los estudiantes de competencias técnicas y transversales críticas para su futuro laboral, sino que también fomenta la continuidad académica hacia estudios de posgrado especializados. El éxito del proyecto confirma que la gestión de la ciberseguridad puede ser una materia sumamente atractiva en el grado universitario si se equilibra el rigor y la profundidad temática con una visión y desarrollo prácticos y motivantes.

AGRADECIMIENTOS

Los autores agradecen a Marc Catrisse por sus valiosas sugerencias y recomendaciones respecto a la documentación técnica utilizada a lo largo de esta metodología docente.

Este trabajo ha sido realizado en el marco del proyecto PID2024-157824OB-I00 financiado por MICIU /AEI /10.13039/501100011033 y por FEDER, UE.

REFERENCIAS

- [1] Master en Ciberseguridad, Universitat Politècnica de Catalunya (UPC), 2026. [En línea]. Disponible en: <https://cybersecurity.masters.upc.edu/> (Accedido: 25 feb. 2026).
- [2] K. Daimi y C. Peoples, *Advances in Cybersecurity Management*. Springer Cham, 2021.
- [3] ISACA, "Certified Information Security Manager (CISM) certification". [En línea]. Disponible en: <https://www.isaca.org/credentialing/cism>.
- [4] Facultad de Informática de Barcelona (FIB), "Guía Docente Gestión de la Ciberseguridad (GCS)", Universitat Politècnica de Catalunya (UPC), curso 2021/2022. [En línea]. Disponible en: <https://web.archive.org/web/20221002231312/https://www.fib.upc.edu/es/estudios/grados/grado-en-ingenieria-informatica/plan-de-estudios/asignaturas/GCS> (Accedido: 25 feb. 2026).
- [5] Facultad de Informática de Barcelona (FIB), "Guía Docente Gestión de la Ciberseguridad (GCS)", Universitat Politècnica de Catalunya (UPC), curso 2025/2026. [En línea]. Disponible en: <https://www.fib.upc.edu/es/estudios/grados/grado-en-ingenieria-informatica/plan-de-estudios/asignaturas/GCS> (Accedido: 25 feb. 2026).
- [6] ENISA, "ENISA Threat Landscape 2025", ENISA reports, oct. 2025. [En línea]. Disponible en: <https://www.enisa.europa.eu/publications/enisa-threat-landscape-2025> (Accedido: 25 feb. 2026).
- [7] Directiva NIS-2, UE 2022/2555, Diario Oficial de la Unión Europea (DOUE) L 333, 27 dic. 2022, pp. 80-152. [En línea]. Disponible en: <https://eur-lex.europa.eu/eli/dir/2022/2555>.
- [8] Regulación Data Act, UE 2023/2854, Diario Oficial de la Unión Europea (DOUE), 2023. [En línea]. Disponible en: <https://eur-lex.europa.eu/eli/reg/2023/2854>.
- [9] B. Al-Sada, A. Sadighian, y G. Oligeri, "MITRE ATT&CK: State of the Art and Way Forward," *ACM Comput. Surv.*, vol. 57, no. 1, Art. 12, 2025. Disponible en: <https://doi.org/10.1145/3687300>.
- [10] OWASP, "Top Ten Web Application Security Risks", 2025. [En línea]. Disponible en: <https://owasp.org/www-project-top-ten/>.
- [11] UPC, "Portal d'Indicadors i dades estadístiques – Enquestes de docència". [En línea]. Disponible en: <https://www.upc.edu/indicadors/> (Accedido: 25 feb. 2026).

Tocando la criptografía: comprender la clave privada con una Máquina Enigma de cartón

Germán Sáez Moreno

Dept. Matemàtiques, Universitat Politècnica de Catalunya-BarcelonaTech
c. Jordi Girona 1-3, 08034, Barcelona, Spain
german.saez@upc.edu

Resumen—Este artículo presenta el diseño y la implementación de una conferencia-taller divulgativa sobre la Máquina Enigma como estrategia para motivar el aprendizaje de la criptografía y la ciberseguridad. Se parte de la importancia de la fase de motivación en cualquier proceso educativo, contextualizando la necesidad del cifrado en conflictos bélicos actuales y en ámbitos civiles como la sanidad, la geolocalización o el comercio electrónico. A través de ejemplos cotidianos se introducen los conceptos de confidencialidad e integridad de la información. Posteriormente se abordan los fundamentos históricos del cifrado mediante el Escítalo Espartano y el Método César, culminando en el estudio práctico de la Máquina Enigma. La utilización de prototipos físicos permite comprender visualmente el funcionamiento interno del cifrado simétrico. La propuesta incorpora además elementos de gamificación para reforzar la participación activa. Finalmente, se destaca el papel en Bletchley Park de Alan Turing y las mujeres criptógrafas en el descifrado de Enigma, integrando historia, tecnología y perspectiva de género en una experiencia educativa completa.

Index Terms—Formación, ciberseguridad, motivación, gamification, Máquina Enigma, clave privada

Tipo de contribución: Formación e innovación educativa

I. INTRODUCCIÓN

La motivación de un tema en una clase de universidad es vital para obtener una predisposición positiva en nuestros alumnos. Y no solo en la universidad o en otro nivel educativo sino también en una conferencia en la que se pretenda explicar un tema complejo. En el caso que presentamos se detallan los planteamientos que se han seguido para el diseño y la puesta en práctica de una conferencia-taller divulgativa sobre la Máquina Enigma, su uso por parte de los nazis y el esfuerzo de los aliados para descifrar los mensajes durante la Segunda Guerra Mundial. Este mismo planteamiento se puede adaptar casi sin modificaciones a la enseñanza de un curso sobre criptografía, ciberseguridad o temas cercanos.

En la didáctica más básica siempre se ha apuntado a las tres fases importantes en todo proceso de enseñanza: la motivación, el desarrollo del tema y la evaluación de los objetivos conseguidos. Después se pueden hacer muchas otras disquisiciones al respecto de cada una de las fases pero estas tres parecen muy importantes. La primera fase es la más olvidada de todas y, a menudo, perdemos los beneficios de motivar los temas y tecnologías que queremos impartir [1]. La motivación está también presente en planteamiento modernos de la enseñanza de la tecnología como es el caso de la iniciativa CDIO [2] (marco educativo internacional nacido en el MIT y que es seguido por algunas universidades españolas). En el caso de una conferencia sobre los sistemas de cifrado de clave privada nos podemos encontrar con el mismo problema. Por esta razón nuestra propuesta ha sido de un formato de




Figura 1. Prototipo de Máquina Enigma de cartón.

conferencia con una parte práctica utilizando unos prototipos de Máquinas Enigma (ver Figura 1), y todo envuelto en las comunicaciones secretas durante la Segunda Guerra Mundial con los condicionantes históricos propios de lo que ocurrió.

II. MOTIVANDO EL CIFRADO DE CLAVE PRIVADA

Siempre tendemos a pensar que la criptografía se ha inventado para nuestro uso actual de Internet. Pero hay que recordar que la criptografía, al igual que Internet, tienen un origen militar. Desgraciadamente la utilización en las guerras de los métodos que garanticen la ciberseguridad son de candente actualidad por las distintas guerras que se están librando, como por ejemplo la contienda bélica entre Ucrania y Rusia, la protagonizada por Hamas y el gobierno de Israel, etc. En cada bando se intercambian mensajes de forma cifrada para que el enemigo no conozca los secretos que pueden resultar decisivos para la evolución de las guerras.

Esta motivación debería abrir los ojos de los asistentes a una clase o a una conferencia-taller para que entiendan la necesidad de la confidencialidad de la información enviada en los mensajes, la integridad, etc. A parte de las utilidades militares vale la pena comentar las que tienen que ver con otras áreas de nuestra sociedad, como son la ciberseguridad en el entorno sanitario o las que tienen que ver con la ciberseguridad en los sistemas de geolocalización.

Respecto a la importancia de la ciberseguridad en el entorno sanitario se pueden poner distintos ejemplos, todos ellos ejemplos clásicos en la literatura. Actualmente los tratamientos médicos se gestionan online por medio de aplicaciones, en las cuáles es muy importante asegurar la privacidad de los

datos médicos del paciente. Estos datos médicos almacenados pueden ser los datos más íntimos de la persona. Esta cuestión puede llegar a ser más que un mero deseo de privacidad: muchas aseguradoras médicas querrían saber los datos médicos de un cliente antes de concederle un seguro médico para así poder economizar en los gastos que a posteriori tendrían que afrontar del cliente; lo mismo ocurre en la contratación en una empresa para la que sea importante saber ciertos aspectos médicos del futuro trabajador y que no tenga derecho legal a conocer. Pero aún puede ser más importante la integridad de la información porque, por ejemplo, un fallo en la integridad de las dosis de la medicación de un paciente crítico, podría llegar a ser muy peligrosa. Por todas estas razones esta conferencia-taller se ha realizado como una actividad más de la Cátedra Carismática. La Cátedra Carismática (de la cual forma parte el autor) es una cátedra concedida por INCIBE a la UPC, liderada por el grupo de investigación ISG-MAK, con el objetivo de divulgar la importancia de la ciberseguridad en el ámbito sanitario [3].

En el caso de la geolocalización también se pueden mostrar diferentes tipologías de problemas que tienen que ver con la ciberseguridad. La confidencialidad de un dato como es nuestra localización en un mapa también es una cuestión de protección de nuestra privacidad. Un caso reciente es el de las balizas de señalación y geolocalización de una avería o un accidente en carretera: si la baliza envía la localización del vehículo averiado o siniestrado sin cifrar, una grúa que intercepte de forma fraudulenta esta información podrá presentarse en el lugar y ofrecer sus servicios cuando el afectado está esperando otro tipo de servicio. Otro ejemplo es la opción de ubicación en directo de algunas aplicaciones. Si ésta no está cifrada, una persona que intercepte la ubicación continuamente se puede considerar que está persiguiendo a la víctima. Esta casuística corresponde al caso de un menor que vuelve a casa de sus padres en una gran ciudad por la noche y comparte su ubicación con sus progenitores. Este planteamiento introductorio es el que se ha utilizado cuando la conferencia-taller se ha realizado en nombre del proyecto SpaceSUITE. El proyecto SpaceSUITE (del cual forma parte el autor) es un proyecto ERASMUS+ para el desarrollo de recursos innovadores de educación y formación en el sector espacial [4].

Se puede introducir algún otro ejemplo muy sencillo y muy fácil de entender como es el caso de la integridad de la información en una compra en Internet. Podemos fijar el caso concreto de una compra de un skin de un juego online de precio 50. Si la integridad no está garantizada, el cobro final anotado por la entidad financiera podría verse modificado apareciendo un 0 al final, con el precio abusivo de 500 (!!!). Este ejemplo es muy palpable para los asistentes viendo clarísimamente que el sistema de cobro tiene que estar blindado contra la posible vulnerabilidad de la integridad. Una cosa es plantear la integridad de la información in abstracto y otra en una situación abusiva como esta.

III. LA MÁQUINA ENIGMA

Todos estos ejemplos permiten motivar a los asistentes, tanto si es un posible futuro estudiante de una ingeniería o simplemente si es un estudiante que comienza el tema de la ciberseguridad y la criptografía en una asignatura de

un grado o un máster de nuestras universidades. Se podrían hacer muchos más ejemplos motivadores (con firmas digitales, establecimiento de claves, etc.) pero nuestro objetivo es centrarnos en una de las herramientas más importantes de la criptografía: los criptosistemas de clave privada para comunicarse de forma cifrada. Los conceptos de canal de comunicación, clave privada común, mensaje en claro y mensaje cifrado se presentan con una introducción histórica, ayudándonos del Método del Escítalo Espartano (s.VI a.C.) y con el Método César (s.I d.C.). En el primer caso se muestra un Escítalo de cartón con un mensaje escrito en una cinta de papel enrollada y varios mensajes desenrollados de este cifrado. Para el segundo caso se muestra una impresión en 3D de un doble disco concéntrico para realizar de forma cómoda el cifrado y el descifrado César. De esta forma se introduce la definición de los conceptos de canal de comunicación, clave privada común, mensaje en claro y mensaje cifrado, de una manera muy intuitiva.

Pero dónde cogió una importancia exagerada la seguridad de las comunicaciones fue durante la Segunda Guerra Mundial en la que los nazis utilizaban la Máquina Enigma como método de cifrado de sus mensajes militares. Esta máquina ideada por el ingeniero alemán Arthur Scherbius en 1918 fue más tarde sofisticada con nuevos añadidos. El ingenio era una máquina electromecánica con forma de máquina de escribir en la que cuando se pulsaba una letra, la energía eléctrica pasaba por un cableado hasta iluminar la letra cifrada en un panel luminoso. Este cableado estaba controlado por tres rotores (cada uno parecido al doble disco concéntrico del método César que se les ha mostrado anteriormente) que albergaban internamente unas conexiones eléctricas que decidían qué letra se iluminaba como letra cifrada. La posición de los rotores constituía la clave privada. Los rotores estaban enlazados uno con el siguiente por unos contactos metálicos que decidían qué letra era la iluminada. Cada vez que se pulsaba una letra para cifrarla se provocaba el movimiento de los rotores siguiendo una serie de reglas y justo antes de iluminarse la letra cifrada. Además, el paso de la energía eléctrica por estos rotores se complicaba ya que después de pasar por los tres rotores se llegaba a una especie de rotor fijo, llamado reflector, que hacía que se volviera a pasar por los tres rotores, pero en este caso en sentido inverso.

Para entender internamente los complejos procesos que se realizan en un sistema de cifrado de clave pública, el caso de la Máquina Enigma es ideal ya que permite ver paso a paso como se obtiene el cifrado. Evidentemente si se utiliza una de las páginas web que se pueden encontrar en Internet para cifrar con una clave privada dada, el proceso se ve como el uso de una caja negra sin apreciar lo ingenioso que resulta internamente el cifrado. Para observar a fondo el proceso de cifrado es muy útil el uso del prototipo propuesto en [5] construido a partir de una caja de vacía de una conocida marca de patatas fritas. En la Figura 1 se puede observar un prototipo construido siguiendo las instrucciones correspondientes. La banda de papel de la izquierda es el reflector y la de la derecha es la entrada y salida del proceso de cifrado (ambas bandas fijas). Las tres bandas centrales corresponden a los tres rotores y son móviles. En estas tres bandas se puede observar el cableado real que une los conectores de ambos lados, de

forma que se puede reseguir la conexión eléctrica de la letra a cifrar, pasar por el rotor tercero, después el segundo, el primero, después el reflector nos envía nuevamente al rotor primero, después se conecta con el segundo, finalmente con el tercero para llegar a la letra cifrada. No hay que olvidarse que antes de cifrar (o descifrar, ya que es el mismo proceso) hay que colocar los rotores en la posición que indica la clave privada (las letras que quedan entre las dos marcas grises) y que antes de proceder a realizar el recorrido del cableado, hay que mover los rotores según unas ciertas reglas.

IV. GAMIFICATION: ¿GAMIFIQUÉ?

Desde hace unos años se está incorporando en las enseñanzas el uso de juegos o pseudojuegos para romper el ritmo de las clases y conseguir una atención más alta. Estas actividades disruptivas en forma de juego es lo que se ha venido a llamar gamification y dosificándolas de forma correcta y con una participación activa, divertida, pero a la vez responsable por parte de los asistentes, resulta muy provechosa [6]. La forma más entretenida de jugar en criptografía es la del desafío de descifrar un mensaje sin conocer la clave utilizada, pero dada la imposibilidad de realizarla en nuestro caso, se plantea buscar el descifrado de una palabra cifrada conociendo la clave utilizada. El objetivo es claro: conseguir que el asistente se haga una idea de la complejidad de realizar un descifrado y a la vez se entienda la dificultad extrema de hacer el mismo descifrado sin conocer la clave secreta (la posición inicial de los rotores).

Después de entender a fondo los mecanismos internos para hacer un descifrado, se explica que para cifrar se procede a explicar y poner en práctica cómo se realiza un cifrado. El cifrado se realiza de la misma manera que un descifrado. Pero en este segundo juego de cifrar con una nueva clave un mensaje, se explican los movimientos que hay que hacer en los rotores en ciertos casos. Para el caso del descifrado se elige una clave privada que haga que sólo se mueva el rotor de la derecha. Para el caso del cifrado la elección de la clave es tal que haya que aplicar ciertas reglas de movimientos de los rotores que se les introduce de forma simplificada.

V. MÁS SOBRE EL PLANTEAMIENTO DE LA CONFERENCIA-TALLER

En la conferencia-taller se plantea una introducción a lo que representa actualmente la criptografía y lo que supuso en el pasado. Un punto clave es la introducción al trabajo realizado en Bletchley Park, centro de los servicios secretos de la Gran Bretaña (MI5) para el descifrado de la Máquina Enigma, sin entrar a fondo en las técnicas utilizadas dada la complejidad de las mismas. También es muy provechoso explicar el importante papel de la mujer en el descifrado de los mensajes de los nazis tal como se ha podido estudiar, una vez desclasificados los documentos secretos. Hay que pensar que el 75 % de los miembros del MI5 en Bletchley Park eran mujeres entre las que siempre se recuerda por sus logros a Joan Clarke, Mavis Batey, Jane Fawcett, Jean Valentine, etc. También permite tratar el tema de la mujer y la ciencia-tecnología, por ejemplo, con el caso de Hedy Lamarr inventora de la tecnología precursora para el Bluetooth, WiFi y GPS moderno que tuvo que huir de la Alemania nazi ya que era hija de familia judía. Es muy importante dar



Figura 2. Conferencia-taller en la Escuela de Enxeñaría de Telecomunicación de la Universidade de Vigo.

la oportunidad que los asistentes vean un documento con una estampación en la portada de la leyenda TOP SECRET autentica, como es el caso del Tratado de Turing sobre la Máquina Enigma [7], documento escrito por Alan Turing en Bletchley Park. Evidentemente hay que hacer referencia a la triste muerte de Alan Turing y los reconocimientos posteriores.

Estos prototipos de Máquina Enigma son muy fáciles de construir, aunque son laboriosos de fabricar. En Internet se puede encontrar todo tipo de información para la construcción y uso de los prototipos (páginas web, pdf's y vídeos). Se ha optado por utilizar el reflector B y los rotores 1, 2 y 3 en este orden, aunque se pueden encontrar los otros reflectores y los otros rotores utilizados en las máquinas reales.

Los errores típicos en la realización de la parte de taller son en primer lugar no utilizar el reflector y suponer que cuando se llega el reflector estamos ante la letra cifrada. Otro de los errores es no recordarse que en la Máquina real los rotores se movían antes que hacer encenderse la bombilla.

VI. RESULTADOS DE LAS CONFERENCIAS-TALLER

Durante el mes de enero de 2025 se llegó a impartir varias conferencias-taller en distintos institutos de la provincia de A Coruña, en la Universidade de Vigo (ver Figura 2) y en el museo de ciencia y tecnología MUNCYT de A Coruña.

En total más de 400 personas pudieron atender a la conferencia-taller en los diversos centros de Galicia.

Cabe destacar un par de artículos aparecidos en prensa [8], [9] sobre la conferencia-taller en Galicia (ver Figura 3).

Durante el final de febrero y comienzo del mes de marzo se hizo lo mismo en varios institutos de la provincia de Sevilla y en la Casa de la Ciencia de Sevilla (CSIC, ver Figura 4).

Unos meses después se realizó la conferencia-taller dentro del CyberCamp UMA organizado por la Universidad de Málaga (ver Figura 5).

También hay que destacar que se ha impartido la conferencia-taller para grupos de estudiantes que visitan la Facultat de Matemàtiques y Estadística de la UPC, dentro de la Setmana de la Ciència organizada por la FCR y en la Festa de la Ciència organizada por el Ayuntamiento de Barcelona.

VII. CONCLUSIONES

Este artículo describe el diseño e implementación de una conferencia-taller sobre la Máquina Enigma como estrategia

LA MÁQUINA ENIGMA: EL CIFRADO SECRETO DE LOS NAZIS Y EL ESFUERZO ALIADO PARA DESCIFRARLO



Figura 3. Conferencia-taller en el MUNCYT de A Coruña.

LA MÁQUINA ENIGMA: EL CIFRADO SECRETO DE LOS NAZIS Y EL ESFUERZO ALIADO PARA DESCIFRARLO

Germán Sáez Moreno
Grupo de Investigación de Matemática Aplicada a la Criptografía de la UPC



Figura 5. Conferencia-taller en el CyberCamp UMA.



Figura 4. Conferencia-taller en la Casa de la Ciencia de Sevilla.

para motivar el aprendizaje de la criptografía y la ciberseguridad. La propuesta parte de la relevancia de la motivación en el proceso educativo y contextualiza la necesidad del cifrado tanto en conflictos actuales como el sanitario, el de geolocalización y en otros ámbitos civiles. Como principal conclusión se cree que la propuesta es motivadora y útil en diferentes escenarios.

Se introducen los conceptos de confidencialidad e integridad mediante ejemplos cotidianos y un recorrido histórico desde el Escítilo Espartano y el Método César hasta el análisis práctico de la Máquina Enigma. El uso de prototipos físicos facilita la comprensión del cifrado simétrico y se incorporan elementos de gamificación para fomentar la participación activa. Finalmente, la experiencia integra historia y perspectiva de género al destacar el papel de Bletchley Park en el descifrado de Enigma.

AGRADECIMIENTOS

El autor desea agradecer a los responsables de la Cátedra Carismática y los del proyecto SpaceSUITE su apoyo para la realización de las conferencias-taller. Así mismo desea agradecer el entusiasmo y apoyo que recibió de los profesores José Luís Quintela, Isaac Agudo, Alberto Pedrouzo y de sus respectivos centros docentes.

REFERENCIAS

- [1] Pintrich, P. R., Schunk, D.H.; Motivación en contextos educativos. Teoría, investigación y aplicaciones. Ed. Pearson Educación, S.A. Madrid, 2006.

- [2] Helene Leong, Ang Jin Shaun, Mark Nivan Singh; Enhancing Students' Self-directed Learning and Motivation; Proceedings of the 12th International CDIO Conference, Turku, Finland, June 12-16 2016.
- [3] <https://carismatica.upc.edu/>
- [4] <https://www.spacesuite-project.eu/>
- [5] <http://wiki.franklinheath.co.uk/index.php/Enigma/>
- [6] López-Fernández, D., Gordillo-Méndez, A., Alarcón-Cavero, P.P. and Tovar-Caro, E.; Comparing Traditional Teaching and Game-Based Learning Using Teacher-Author Games on Computer Science Education; IEEE Transactions on Education, v. 64 (n. 4); pp. 367-373.
- [7] <https://www.archives.gov/files/press/press-releases/2015/images/turing-enigma-treatise.pdf>
- [8] Quintela-Julián, José Luís; La guerra, Enigma, Turing y Germán; La Opinión A Coruña; 22 de enero de 2025. <https://www.laopinioncoruna.es/opinion/2025/01/22/guerra-enigma-turing-german-113594606.html>
- [9] Quintela-Julián, José Luís; Enigma; Galicia Confidencial; 20 de febrero de 2025. <https://www.galiciacconfidencial.com/noticia/5490718-enigma>

Sesión de Investigación 7 - Software y sistemas para la ciberseguridad

A Review of EAP-FIDO: A Novel EAP Method for Using FIDO2 Credentials for Network Authentication

Martíño Rivera-Dourado^{1,2*}, Christos Xenakis³, Alejandro Pazos^{1,2}, Jose Vázquez-Naya^{1,2}

¹ RNASA-IMEDIR, Universidade da Coruña, Facultade de Informática, Campus de Elviña, A Coruña, 15071, Spain

² Centro de Investigación CITIC, Universidade da Coruña, Campus de Elviña, A Coruña, 15071, Spain

³ Department of Digital Systems, University of Piraeus, Piraeus, 18532, Greece

* Corresponding author: martino.rivera.dourado@udc.es

Abstract—EAP-FIDO is a novel EAP method bringing FIDO2 credentials to WPA2/3-Enterprise and MACSec networks. By tunnelling FIDO2 challenge-response exchanges within PEAP or EAP-TTLS, EAP-FIDO ensures mutual authentication, verifying the user identity via the FIDO2 authentication that does not involve the deployment overhead of client certificates, allowing organisations to unify web and network authentication credentials. We review the protocol design, prototype performance, and security analysis, demonstrating its viability as a secure, scalable, and standards-compliant solution for modernising network authentication.

Index Terms—network authentication, Extensible Authentication Protocol, 802.1X, WPA2-Enterprise, wireless, MACSec, FIDO2, security key, passkey

Type of contribution: *Already published research.*

I. INTRODUCTION

Passwordless authentication, exemplified by the FIDO2 project, is rapidly replacing passwords in web applications and operating systems to mitigate risks like phishing and credential theft. However, network authentication in corporate environments using IEEE 802.1X framework still predominantly relies on password-based EAP methods, like EAP-MD5 or PEAP-MSCHAPv2. While EAP-TLS offers strong certificate-based security, its PKI complexity in deployment reduces its adoption.

This paper reviews EAP-FIDO [1], a novel EAP method bringing FIDO2 credentials to WPA2/3-Enterprise and MACSec networks. By tunnelling FIDO2 challenge-response exchanges within PEAP or EAP-TTLS, EAP-FIDO ensures mutual authentication and channel security without the overhead of client certificates, allowing organisations to unify web and network authentication credentials. We present the protocol design, prototype performance, and security analysis.

II. EAP-FIDO PROTOCOL

EAP-FIDO [1] is a novel EAP method designed to bring FIDO2 [3] passwordless authentication to network environments. The protocol follows the modular design of the EAP framework, ensuring interoperability with existing network infrastructure like IEEE 802.1X, WPA2/3-Enterprise, and MACSec. It relies on FIDO2's asymmetric cryptography, where the client signs a challenge provided by the server using a private key stored in an authenticator.

The design of EAP-FIDO focuses on maintaining the integrity of the authentication process while ensuring mutual authentication. To achieve this, the protocol messages are tunnelled within PEAP or EAP-TTLS frames. This encapsulation allows the client to authenticate the server via TLS before any FIDO2 credentials are exchanged, protecting the communication from eavesdropping. Additionally, EAP-FIDO binds challenge-response exchanges to the session context to prevent replay and man-in-the-middle attacks. To optimise performance and minimise latency, EAP-FIDO also incorporates a fast re-authentication strategy [2] that extends EAP sessions and reduces the need for repetitive FIDO2 authentication operations.

A. Protocol architecture

The architecture presented in Figure 1 integrates standard EAP components with FIDO2 roles. The **User Equipment** acts as both EAP Supplicant and FIDO2 Client, encapsulating FIDO2 messages within EAP packets tunnelled inside PEAP or EAP-TTLS for confidentiality. The **Access Point (Authenticator)** functions as a transparent pass-through entity, forwarding EAPoL frames to the AS via RADIUS, requiring no hardware modifications. The **Authentication Server (AS)**, acting as the FIDO2 Server, terminates the TLS tunnel, extracts FIDO2 messages, and verifies assertions against registered public keys. Upon success, both peer and server derive a Master Session Key (MSK) for the 802.1X session.

B. Protocol operation

EAP-FIDO operation is structured into three main stages: Initialisation, FIDO-Start, and FIDO-Request. During the **Initialisation** (EAP-Identity), the Supplicant provides an identity (username) to the server. If using discoverable credentials (resident keys), an anonymous identity can be used.

In the **FIDO-Start** stage, an Elliptic Curve Diffie-Hellman (ECDH) key exchange takes place between the Authentication Server (AS) and the EAP-Peer (Supplicant). The AS generates an ephemeral key pair and sends its public key along with a nonce to the peer. The peer responds with its own public key, and both parties derive a shared secret. This secret is then used to generate the Master Session Key (MSK), which secures the subsequent 802.1X session. This stage also supports a fast re-authentication mechanism where the peer




Fig. 1. Architecture of the FIDO Extensible Authentication Protocol Method (EAP-FIDO). In blue, the FIDO2 components; in white, EAP components. Optionally, an outbound registration service for FIDO2.

can prove possession of a valid session cookie from a previous authentication to bypass the full FIDO2 flow.

Finally, in the **FIDO-Request** stage, the AS sends a FIDO2 challenge to the Supplicant, including the Relying Party (RP) ID and a list of allowed credentials. The Supplicant forwards this to the FIDO2 authenticator, which performs user verification (e.g., via PIN or biometrics) and signs the client data. It is important to highlight that this client data is the result of the cryptographic contextual binding of the the EAP session id and the FIDO2 challenge. Then, the resulting FIDO2 assertion is sent back to the AS. The AS validates the signature against the stored public key for that user. If successful, the authentication is completed, and network access is granted.

III. RESULTS AND CONCLUSION

EAP-FIDO¹ is a method proposed as a solution to bring FIDO2 to network authentication. Our experimental results demonstrate its viability in real-world scenarios, particularly in Wi-Fi networks. The prototype implementation shows that EAP-FIDO achieves an authentication time of approximately 0.67 seconds, regardless of whether server-side or discoverable credentials are used. While this introduces some overhead compared to simpler methods, it is largely due to the FIDO2 authentication within the Phase 2 of PEAP. However, the proposed fast re-authentication mechanism significantly reduces this latency, achieving re-authentication in under 40 milliseconds by bypassing the full FIDO2 flow.

From a security perspective, EAP-FIDO offers robust protection against common network attacks. By tunnelling FIDO2 messages within a TLS channel (PEAP/EAP-TTLS), it ensures confidentiality and server authentication, mitigating eavesdropping and rogue AS attacks. The use of FIDO2's public-key cryptography prevents credential theft via Evil Twin attacks, as private keys never leave the authenticator. Furthermore, the binding of the FIDO2 challenge to the EAP session ID effectively prevents Man-in-the-Middle (MitM)

and replay attacks. Privacy is also addressed by supporting anonymous identities with discoverable credentials, minimising PII exposure.

EAP-FIDO is particularly well-suited for corporate networks, allowing organisations to leverage existing FIDO2 credentials used for web SSO to secure network access, thereby unifying the authentication experience. It also may be used for public hotspots, where it can provide secure, passwordless access for guests without complex registration processes. In conclusion, EAP-FIDO presents a secure, scalable, and standards-compliant solution for modernising network authentication, effectively bridging the gap between web and network security models.

ACKNOWLEDGMENTS

This work was funded by EU and "Xunta de Galicia" (Spain), grant ED431C 2022/46–Competitive Reference Groups GRC. This work was also supported by CITIC, as a center accredited for excellence within the Galician University System and a member of the CIGUS Network, which receives subsidies from the Department of Education, Science, Universities, and Vocational Training of the "Xunta de Galicia". Additionally, CITIC is co-financed by the EU through the FEDER Galicia 2021-27 operational program (Ref. ED431G 2023/01). This research has been partially funded by the European Union's research and innovation programme under grant agreement No. 101095634 (ENTRUST). The work is also funded by the "Formación de Profesorado Universitario" (FPU) grant from the Spanish Ministry of Universities to Martiño Rivera Dourado (Grant FPU21/04519).

REFERENCES

- [1] M. Rivera-Dourado, C. Xenakis, A. Pazos, and J. A. Vázquez-Naya, "EAP-FIDO: A novel EAP method for using FIDO2 credentials for network authentication," *Comput. Netw.*, vol. 266, Art. no. 111348, 2025. doi:10.1016/j.comnet.2025.111348.
- [2] D. Mortágua, A. Zúquete, and P. Salvador, "Enhancing 802.1X authentication with identity providers using EAP-OAUTH and OAuth 2.0", *Computer Networks*, vol. 244, p. 110337, May 2024, doi: 10.1016/j.comnet.2024.110337 .
- [3] A. Angelogianni, I. Politis, and C. Xenakis, "How many FIDO protocols are needed? Analysing the technology, security and compliance", *ACM Comput. Surv.*, Mar. 2024, doi: 10.1145/3654661.

¹Draft implementation available: <https://github.com/martinord/eap-fido>

qcrypto: Librería para la Simulación y Desarrollo de Protocolos Criptográficos Cuánticos

Jorge Garcia-Diaz
Universidad de La Laguna
La Laguna, Tenerife
jgarcidi@ull.edu.es

Daniel Escanez-Exposito
Universidad de La Laguna
La Laguna, Tenerife
jescanez@ull.edu.es

Pino Caballero-Gil
Universidad de La Laguna
La Laguna, Tenerife
pcaballe@ull.edu.es

Resumen—El reciente avance de las tecnologías cuánticas requiere un desarrollo proactivo de soluciones criptográficas robustas que puedan resistir los ataques de futuros adversarios cuánticos. Este artículo presenta *qcrypto*, una novedosa librería de Rust de código abierto diseñada para la exploración científica, simulación y pruebas rigurosas de primitivas criptográficas cuánticas. Esta se ha desarrollado utilizando íntegramente el lenguaje Rust, aprovechando sus garantías de seguridad de memoria, concurrencia de subprocesos y alto rendimiento, fundamentales para simular con precisión protocolos cuánticos que requieren un gran esfuerzo computacional.

Index Terms—Criptografía Cuántica, Simulación Cuántica, Información Cuántica, Rust, QKD

Tipo de contribución: *Investigación original*

I. INTRODUCCIÓN

La inminente llegada de la computación cuántica a gran escala plantea una amenaza sin precedentes para la seguridad de la infraestructura de comunicaciones global. Algoritmos cuánticos, como el de Shor [1], tienen el potencial de quebrar en tiempo polinómico los esquemas de criptografía asimétrica en los que se sustenta la seguridad digital actual (RSA, Curvas Elípticas) [2]. Como respuesta a este paradigma, la Criptografía Cuántica emerge como la solución definitiva, garantizando una seguridad basada en las leyes inquebrantables de la física (seguridad teórica de la información), apoyándose en postulados como el teorema de no-clonación y el principio de incertidumbre de Heisenberg. Protocolos como la Distribución Cuántica de Claves (QKD) y las Pruebas de Conocimiento Nulo Cuánticas (QZKP) [3] representan el estándar futuro para la autenticación y el intercambio seguro de información.

Sin embargo, la transición de los protocolos criptográficos desde el diseño teórico matemático hasta su implementación en hardware físico real es un desafío tecnológico monumental. Las implementaciones físicas están irremediablemente sometidas a imperfecciones de los dispositivos, ruido ambiental y atenuación de la señal. Por ello, la simulación por software constituye una etapa indispensable y crítica para probar, validar y someter a estrés las primitivas criptográficas antes de su despliegue físico.

El problema metodológico actual radica en que la inmensa mayoría de los simuladores cuánticos existentes son herramientas de propósito general, optimizadas para el diseño de circuitos y algoritmos lógicos en computadoras cuánticas tolerantes a fallos. Estos simuladores suelen basar su motor de cálculo en la evolución de vectores de estado puros (*state-vector simulators*). Este enfoque es matemáticamente insuficiente para modelar la realidad de un canal de comunicación

criptográfico, ya que los sistemas puros no pueden representar la decoherencia, el ruido, la pérdida de entrelazamiento con el entorno (sistemas abiertos) ni las estrategias de medición no proyectivas.

Para solventar esta carencia en el ecosistema de investigación, este trabajo presenta *qcrypto* [4]: una librería de Rust desarrollado íntegramente en este mismo lenguaje [5], concebido específicamente para la simulación, diseño y validación de protocolos de criptografía cuántica.

A diferencia de los simuladores genéricos, *qcrypto* fundamenta su arquitectura central en el formalismo de matrices de densidad (ρ), operadores de Kraus y Medidas Generalizadas u Operadores Positivos de Medición (POVM). Esta base matemática permite modelar de forma precisa y nativa la física de los sistemas cuánticos abiertos y el ruido del canal. Además, la librería aprovecha el riguroso sistema de tipos de Rust y la paralelización computacional masiva para ofrecer simulaciones de alto rendimiento, seguras en memoria y estadísticamente reproducibles, proporcionando a los investigadores una herramienta sin precedentes para evaluar la robustez de los protocolos criptográficos frente a modelos de ruido realistas y ataques de adversarios.

El resto de este artículo se estructura de la siguiente manera: la Sección II analiza el estado del arte y los trabajos relacionados en el ámbito de la simulación cuántica. La Sección III asienta las bases matemáticas y los conceptos físicos preliminares sobre los que se fundamenta el simulador. La Sección IV desgana la arquitectura interna de *qcrypto*, detallando sus estructuras de datos, módulos y protocolos implementados, incluyendo un caso de uso práctico. La Sección V presenta las métricas y la evaluación de rendimiento computacional de la librería bajo distintos escenarios de estrés. Finalmente, la Sección VI expone las conclusiones derivadas de este trabajo y plantea las futuras líneas de investigación y desarrollo.

II. ESTADO DEL ARTE Y TRABAJOS RELACIONADOS

El desarrollo de software para la simulación de sistemas cuánticos ha estado históricamente dominado por lenguajes como Python y C++. En la actualidad, el ecosistema cuenta con herramientas robustas y ampliamente adoptadas, tales como Qiskit (IBM) [6] y Cirq (Google) [7]. Sin embargo, estos frameworks son simuladores de propósito general orientados fundamentalmente a la computación cuántica basada en puertas cuánticas y algoritmos sobre sistemas cerrados. Al centrar su motor computacional en la evolución de vectores de estado puros, carecen de las abstracciones nativas necesarias para modelar con precisión el ruido, la decoherencia y los

canales adversarios, elementos intrínsecos de la criptografía cuántica.

Para el estudio de sistemas cuánticos abiertos, herramientas como QuTiP (Quantum Toolbox in Python) [8] representan el estándar de facto en la comunidad física. Aunque QuTiP maneja eficazmente matrices de densidad y operaciones no unitarias, su dependencia del ecosistema Python (apoyado en extensiones C/C++) introduce sobrecargas en tiempo de ejecución y dificulta la integración segura y eficiente en entornos de producción de software de alto rendimiento. Por otro lado, simuladores especializados en comunicaciones cuánticas, como NetSquid [9] o SeQUeNCe [10], enfocan su arquitectura en la simulación de redes a nivel macroscópico (topologías, latencia, repetidores), abstrayendo o simplificando en exceso la validación microscópica de las primitivas criptográficas y la aplicación de Medidas Generalizadas.

Dentro del ecosistema del lenguaje Rust, la adopción de herramientas cuánticas se encuentra en una fase incipiente. Los paquetes disponibles actualmente se limitan a la evaluación básica de circuitos cuánticos. Hasta la fecha, no existe ninguna librería nativa escrita puramente en Rust que esté especializada en criptografía cuántica.

El desarrollo de `qcrypto` surge precisamente para llenar este vacío en el estado del arte. Al estar implementada 100 % en Rust, la librería prescinde de dependencias externas en C/C++. Esto dota a la comunidad científica de una herramienta sin precedentes: un entorno nativo en Rust, diseñado desde su núcleo en torno a matrices de densidad y operadores de Kraus, y optimizado específicamente para el diseño, simulación y validación de protocolos criptográficos bajo modelos de ruido físicos realistas.

III. PRELIMINARES

En esta sección se introducen las bases en la que basa este trabajo. Se definirán y explicarán los conceptos fundamentales en los que se apoya `qcrypto`.

III-A. Estados de Cúbits

Asociado a cualquier sistema físico hay un $\mathbb{C}$ -Espacio Vectorial con producto interno, es decir, un espacio de Hilbert (en dimensión finita). A este espacio de Hilbert se le conoce como el espacio de estado del sistema. Cualquier sistema está descrito por su vector de estado, el cual es un vector normal ($\langle\psi|\psi\rangle = 1$).

Uno de los sistemas más simples es el sistema de un cúbit. Este tiene un espacio de estado de 2 dimensiones, específicamente $\mathbb{C}^2$. Por tanto, se puede definir de manera general el vector de estado para un cúbit.

Definición 1 (Vector de Estado de un Cúbit): Un vector de estado en superposición de un solo cúbit es una combinación lineal:

$$\alpha_0 |0\rangle + \alpha_1 |1\rangle, \quad \alpha_0, \alpha_1 \in \mathbb{C} \wedge \|\alpha_0\|^2 + \|\alpha_1\|^2 = 1. \quad (1)$$

En general, un sistema físico puede estar compuesto por varios subsistemas. En otras, palabras, el espacio de estado de un sistema puede ser construido a partir de los espacios de estado de los subsistemas que lo componen. En general, el espacio de estado de un sistema compuesto es el producto tensorial de los espacios de estado de los sistemas físicos que lo componen. Es más, teniendo los subsistemas enumerados

de 1 a n , y el sistema i está en el estado $|\psi_i\rangle$, entonces el estado del sistema compuesto es:

$$\bigotimes_{i=1}^n |\psi_i\rangle. \quad (2)$$

Por tanto, el espacio de estado para un sistema de n cúbits es $\mathbb{C}^{2^n}$. Un aspecto muy relevante de cara a la simulación de este tipo de procesos es que el número de entradas de un estado de n cúbits escala de manera exponencial con respecto al número de cúbits ($\mathcal{O}(2^n)$). De la misma manera que se hizo para un cúbit, se puede definir explícitamente el vector de estado para n cúbits.

Definición 2 (Vector de Estado de n cúbits): Para varios cúbits, los estados de superposición son combinaciones lineales de la forma:

$$\sum_{i=0}^{2^n-1} \alpha_i |i_n\rangle, \quad \alpha_i \in \mathbb{C} : \sum_{i=0}^{2^n-1} \|\alpha_i\|^2 = 1. \quad (3)$$

Una vez se han definido los posibles estados de un sistema físico, es oportuno estudiar como evoluciona dicho sistema.

III-B. Evolución del Sistema

La evolución de un sistema cerrado en momentos discretizados es descrito por transformaciones unitarias del vector de estado del sistema. En otras palabras, el estado $|\psi\rangle$ de un sistema en el momento t_1 está relacionado por con el estado del sistema $|\psi'\rangle$ en el momento t_2 por un operador unitario U que solo depende de los momentos t_1 y t_2 :

$$|\psi'\rangle = U |\psi\rangle. \quad (4)$$

En la teoría de la computación cuántica, a estos operadores unitarios se les suele denominar puertas cuánticas. Visto desde un punto de vista informático, se pueden definir puertas cuánticas que actúen de manera local, es decir, en un subconjunto de los cúbits que componen el sistema total.

III-C. Mediciones Cuánticas

Para poder modelar y explicar matemáticamente lo que ocurre cuando el sistema es observado (deja de ser cerrado), se utilizan las mediciones cuánticas.

Las mediciones cuánticas están descritas por una colección $\{M_m\}$ de operadores de medición. Estos operadores actúan sobre el espacio de estado del sistema que ha sido observado. El índice m hace referencia a los posibles resultados de la medición. Si el sistema cuántico está en un estado $|\psi\rangle$ justo el instante en el que sea realiza la medición, entonces las probabilidades de obtener cada resultado m viene dado por:

$$p(m) = \langle\psi|M_m^\dagger M_m|\psi\rangle \quad (5)$$

y el estado del sistema después de la medición, condicionado a que haya salido el resultado m , es:

$$|\psi_m\rangle = \frac{M_m |\psi\rangle}{\sqrt{\langle\psi|M_m^\dagger M_m|\psi\rangle}} = \frac{M_m |\psi\rangle}{\sqrt{p(m)}}. \quad (6)$$

Los operadores de medición deben satisfacer la relación de completitud:

$$\sum_m M_m^\dagger M_m = I. \quad (7)$$

Esto garantiza que la probabilidad total sea 1, es decir:

$$\begin{aligned}\sum_m p(m) &= \sum_m \langle \psi | M_m^\dagger M_m | \psi \rangle \\ &= \langle \psi | \sum_m M_m^\dagger M_m | \psi \rangle = \langle \psi | I | \psi \rangle \\ &= \langle \psi | \psi \rangle = 1.\end{aligned}\quad (8)$$

Un tipo especial de mediciones y de gran relevancia en computación y comunicaciones cuánticas son las mediciones proyectivas. Formalmente, una medición proyectiva es descrita por un observable M , el cual es un operador Hermítico ($M^\dagger = M$) que actúa en el espacio de estado del sistema. Como M es un operador Hermítico, permite su descomposición espectral:

$$\text{Hermítico} \Leftrightarrow M^\dagger = M \Rightarrow MM^\dagger = M^\dagger M \Leftrightarrow \text{Normal}. \quad (9)$$

Por tanto, su descomposición espectral se puede escribir como:

$$M = \sum_m m P_m, \quad (10)$$

donde P_m es el proyector al autoespacio de M con autovalor m . Los posibles valores de la medición corresponden con los autovalores m . Cuando se mide el estado $|\psi\rangle$, la probabilidad de obtener m es:

Las mediciones proyectivas se pueden entender como un caso especial de las mediciones generales de la mecánica cuántica antes descritas. Suponiendo que la medición descrita por $\{M_m\}$ cumple la relación de completitud ($\sum_m M_m^\dagger M_m = I$) y una condición adicional de que sean proyectores ortogonales, esto es:

$$M_m M_{m'} = \delta_{m,m'} M_m. \quad (11)$$

De esta manera, se obtienen las mismas expresiones que en las Ecuaciones 5 y 6. En general, en vez de dar un observable M para describir una medición proyectiva, se suelen listar un conjunto $\{P_m\}$ de operadores ortogonales completos ($\sum_m P_m = I$ y $P_m P_{m'} = \delta_{m,m'} P_m$), siendo implícitamente $M = \sum_m m P_m$ el observable utilizado para la medición. Otro tipo de nomenclatura muy usada es “medir con respecto a la base $\{|m\rangle\}$ ”, lo que simplemente significa usar una medición proyectiva dada por $P_m = |m\rangle\langle m|$.

III-D. Operadores de Densidad

Los operadores de densidad ofrecen un lenguaje muy conveniente para describir sistemas cuánticos cuyo estado no es sabido con exactitud. Explícitamente, suponiendo que un sistema cuántico está en uno de los estados $|\psi_i\rangle$ con probabilidad p_i . El operador de densidad que describe el estado del sistema es el siguiente:

$$\rho = \sum_i p_i |\psi_i\rangle\langle\psi_i|. \quad (12)$$

Si $\rho = |\psi\rangle\langle\psi|$, se dice que el sistema está en un estado puro. En otro caso, se dice que está en un estado mixto.

Para distinguir si un sistema está en un estado puro o mixto, se debe estudiar la traza del operador ρ^2 . Se puede demostrar que la traza de cualquier operador de densidad al cuadrado ρ^2 es menor o igual a 1, con igualdad si, y solo si, ρ representa un estado puro.

Al igual que los vectores de estado, el operador de densidad describe completamente el espacio de estado. En concreto, si el sistema está en el estado ρ_i con probabilidad p_i , el operador de densidad que describe el sistema es:

$$\sum_i p_i \rho_i. \quad (13)$$

El análogo de la evolución del sistema usando el operador de densidad también viene definido por operaciones unitarias U (puertas cuánticas), pero que actúan de la siguiente manera sobre el operador de densidad:

$$\rho' = U \rho U^\dagger. \quad (14)$$

Pasando, computacionalmente hablando, de una multiplicación de matrices a dos de ellas por cada transformación unitaria individual aplicada al sistema descrita por ρ .

En el caso de las mediciones del sistema, se sigue describiendo las mediciones con un conjunto $\{M_m\}$ con m como el posible resultado de la medición. Estos operadores cumplen que la probabilidad de obtener el resultado m en la medición es:

$$p(m) = \text{tr}(M_m^\dagger M_m \rho), \quad (15)$$

y el estado del sistema después de la medición es:

$$\rho_m = \frac{M_m \rho M_m^\dagger}{\text{tr}(M_m^\dagger M_m \rho)} = \frac{M_m \rho M_m^\dagger}{p(m)}. \quad (16)$$

Además que los operadores de medición deber seguir cumpliendo la relación de completitud descrita en la Ecuación 7.

III-E. Canales Cuánticos

En las subsecciones anteriores se abordó la evolución de sistemas cerrados mediante operadores unitarios. Sin embargo, en escenarios físicos reales, los sistemas cuánticos rara vez están completamente aislados; generalmente interactúan con su entorno. Esta interacción provoca fenómenos como la pérdida de información o la *decoherencia*. Para modelar la evolución dinámica general de un sistema cuántico abierto, se introduce el formalismo de los canales cuánticos.

Un canal cuántico, también conocido como operación cuántica o mapa cuántico, es la transformación física más general que puede sufrir un estado cuántico. Matemáticamente, es una transformación lineal $\mathcal{E}$ que mapea operadores de densidad en operadores de densidad:

$$\rho' = \mathcal{E}(\rho). \quad (17)$$

Para que esta transformación represente un proceso físico válido, el mapa $\mathcal{E}$ debe satisfacer dos propiedades fundamentales:

1. Preservación de la traza: La probabilidad total debe conservarse, es decir, $\text{tr}(\mathcal{E}(\rho)) = \text{tr}(\rho) = 1$.
2. Completamente positivo: El operador resultante debe ser un operador de densidad válido (semi-definido positivo). Además, esta propiedad debe mantenerse incluso si aplicamos el canal $\mathcal{E}$ a un subsistema A que se encuentra entrelazado con un subsistema arbitrario B que no es afectado por el canal.

Por la conjunción de estas dos propiedades, a los canales cuánticos se les conoce formalmente en la literatura como mapas CPTP (por sus siglas en inglés, Completely Positive Trace-Preserving).

Una forma extremadamente útil y elegante de representar estos canales, que conecta de manera directa con la noción de medición descrita anteriormente, es mediante el teorema de representación de Kraus (o representación de suma de operadores). Cualquier canal cuántico $\mathcal{E}$ puede expresarse como:

$$\mathcal{E}(\rho) = \sum_k E_k \rho E_k^\dagger, \quad (18)$$

donde los operadores $\{E_k\}$, conocidos como operadores de Kraus, actúan sobre el espacio de estado del sistema principal. Para garantizar que el canal preserve la traza, estos operadores deben satisfacer una relación de completitud casi idéntica a la vista en las mediciones cuánticas:

$$\sum_k E_k^\dagger E_k = I. \quad (19)$$

El poder de la representación de Kraus radica en que engloba de manera natural las dinámicas previamente estudiadas. Si el conjunto de operadores de Kraus contiene un único elemento $E_1 = U$ (donde U es unitario), se recupera de manera exacta la evolución de un sistema cerrado estipulada anteriormente: $\rho' = U\rho U^\dagger$.

Por otro lado, si consideramos un proceso de medición cuántica como el descrito por la colección $\{M_m\}$, pero en el cual el resultado de la medición se pierde, se ignora o no se registra (lo que se conoce como una medición no selectiva), el estado promedio resultante del sistema es exactamente $\sum_m M_m \rho M_m^\dagger$. Esto evidencia que una medición cuántica sin lectura de resultados actúa, a todos los efectos prácticos, como un canal cuántico que introduce decoherencia en el sistema.

Nótese que no se asegura que el resultado de un canal cuántico $\mathcal{E}(\rho)$ sea un estado puro incluso si la entrada ρ sí lo es. Por tanto, si se quiere simular canales cuánticos ruidosos, es necesario trabajar con operadores de densidad, generalizando el concepto de vector de estado. Esto implica sacrificar eficiencia de memoria y de multiplicación de matrices, pero como se verá en las siguientes secciones, esta librería está optimizada para mitigar estos problemas en el contexto de simulaciones de protocolos criptográficos cuánticos.

IV. ESTRUCTURA DE LA LIBRERÍA

La librería *qcrypto* ha sido diseñada empleando una arquitectura modular que persigue un objetivo claro: proporcionar un entorno de simulación estructurado, de alto rendimiento computacional y rigurosamente exacto desde el punto de vista físico para protocolos de criptografía cuántica. Diferenciándose de los simuladores genéricos que optimizan la evolución de vectores de estado en circuitos lógicos ideales, *qcrypto* se cimienta matemáticamente en el formalismo de matrices de densidad. Esta elección de diseño fundamental posibilita la representación nativa de sistemas cuánticos abiertos, permitiendo el estudio de la decoherencia, la degradación del entrelazamiento y la aplicación de medidas generalizadas. El desarrollo de la librería se ha llevado a cabo de forma íntegra en *Safe Rust*, lo que garantiza seguridad en el manejo de memoria y elimina dependencias externas, al mismo tiempo

que maximiza el rendimiento mediante la paralelización de operaciones matriciales masivas.

La estructura interna del *framework* se organiza en torno a los componentes físicos del sistema, sobre los cuales se construyen capas de abstracción superiores que orquestan las rutinas criptográficas complejas. A continuación, se detallan las estructuras centrales que componen la base de la librería.

IV-A. *QuantumState*

El estado del sistema se encapsula en la estructura central *QuantumState*, la cual asume la responsabilidad de representar matemáticamente el sistema multi-qubit a través de su matriz de densidad iterada (ρ). Para garantizar la coherencia física, esta estructura cuenta con rutinas de inicialización y validación (*new()*, *from_state_vector()*, *from_density_matrix()*) que verifican continuamente propiedades inalienables como la hermiticidad y la conservación de la traza unitaria.

La evolución del sistema bajo condiciones ideales (cerradas) se gestiona mediante transformaciones tensoriales locales a través de métodos como *apply()* y *apply_controlled()*. Esta aproximación es computacionalmente eficiente, ya que al operar el sistema por partes se elude el coste temporal restrictivo asociado a las multiplicaciones globales de matrices exponenciales de tamaño $\mathcal{O}(2^N \times 2^N)$.

El proceso de medida se aborda separando la mecánica estadística del colapso físico real. Por un lado, métodos como *set_measurement()* permiten obtener las distribuciones probabilísticas puras sin perturbar el sistema; por otro, rutinas como *measure()* simulan activamente el colapso del estado, actualizando y normalizando la matriz de densidad interna en función del resultado proyectado.

Finalmente, la estructura dota al sistema de herramientas para modelar la decoherencia mediante la inyección de tensores de Kraus y ruido a través de *apply_channel()*. Este proceso se encuentra altamente paralelizado internamente, permitiendo además la composición de estados de gran escala mediante el producto de Kronecker (*compose()*).

IV-B. *Gate*

Las transformaciones unitarias locales o globales que actúan sobre el estado se definen en la estructura *Gate*. Esta entidad aloja su propia representación matricial subyacente y opera directamente como el motor de evolución temporal del sistema.

Gate expone constructores estándar que engloban el conjunto de compuertas universales más recurrentes en la literatura cuántica, incluyendo las matrices de Pauli (*x()*, *y()*, *z()*), la transformación de Hadamard (*h()*), las compuertas de fase (*s()*, *t_gate()*), y los operadores entrelazados condicionales (*cnot()*, *swap()*, *toffoli()*).

La librería ofrece el método *expand_gate()* para integrar estas transformaciones locales en sistemas de mayor escala. Este mecanismo envuelve matemáticamente los operadores definidos para un subconjunto restringido de qubits mediante productos tensoriales con matrices identidad.

Sin embargo, la librería implementa funciones como *apply_local_left* y *trace()* las cuales son las encargadas de aplicar puertas cuánticas a estados cuánticos de

manera eficiente, prescindiendo de calcular y modificar las entradas relacionadas a las matrices de identidad del operador expandido.

IV-C. Measurement

El formalismo de medida del sistema, tanto para medidas proyectivas tradicionales como para POVMs, se encapsula en la estructura `Measurement`.

Para asegurar la rigurosidad matemática y física, las rutinas de inicialización, tales como `from_povm()`, imponen y validan invariablemente la relación de completitud (esto es, garantizan $\sum_k M_k^\dagger M_k = I$). Además, la estructura facilita la experimentación criptográfica proveyendo bases constantes predefinidas de uso intensivo, como las bases computacionales (`z_basis()`), diagonales (`x_basis()`) y circulares (`y_basis()`). Todo esto, siempre permitiendo al usuario construir sus propias mediciones cuánticas generalizadas.

IV-D. QuantumChannel

La simulación de canales cuánticos ruidosos se consigue mediante `QuantumChannel`, una estructura que representa mapas físicos completamente positivos y que preservan la traza. Esta entidad es fundamental para estudiar la propagación de errores en entornos realistas.

La estructura permite inyectar operadores de Kraus, pudiendo simular cualquier tipo de canal cuántico. Esta librería ofrece algunos canales mas usados e importantes por defecto, desde canales clásicos discretos (`bit_flip()`, `phase_flip()`, `bit_phase_flip()`, `depolarizantes`) hasta ruidos continuos asimétricos, como la relajación longitudinal (`amplitude_damping()`) y la pérdida de coherencia transversal (`phase_damping()`).

Asimismo, `QuantumChannel` provee rutinas de interconexión para componer dinámicas de error complejas. Los canales pueden concatenarse multiplicativamente mediante `compose()`, o combinarse bajo ponderaciones estocásticas utilizando `mix()`.

IV-E. Sampler

Para la ejecución iterativa de experimentos de alto volumen, tales como simulaciones de tipo Monte Carlo, la librería aporta el `Sampler`. Este entorno estadístico aislado ejecuta la rutina `run()`, la cual, tras deducir la función de distribución acumulada del estado inicial, emula la extracción de miles o millones de observaciones (*shots*).

El diseño del `Sampler` permite registrar los resultados secuenciales en estructuras de datos optimizadas sin incurrir en el desgaste computacional de mutar iterativamente la matriz de densidad subyacente. Opcionalmente, permite la integración dinámica de un `QuantumChannel`, simulando así el comportamiento del sistema ante la presencia constante de ruido ambiental.

IV-F. Módulos de Soporte

Más allá de las estructuras físicas base, `qcrypto` se apoya en una serie de módulos que definen la lógica computacional, albergan las utilidades matemáticas y garantizan la solidez del software:

- **utils:** Constituye el pilar del álgebra lineal interna. Exporta manipulaciones que optimizan el manejo de

estructuras de datos matriciales, incluyendo la paralelización recursiva para operadores a gran escala, la verificación de hermiticidad y el producto masivo de Kronecker. Alivianando la complejidad algorítmica, funciones como `apply_local_left` y `trace()` son fundamentales para mantener los tiempos de ejecución de las simulaciones en rangos asumibles.

- **rng:** Módulo utilitario encargado de abstraer la generación pseudoaleatoria que rige la naturaleza estocástica del sistema cuántico. Este componente implementa un sistema Thread-Local (RNG) de alto rendimiento, el cual permite anclar las simulaciones a semillas deterministas. Esta característica es indispensable para la investigación, pues asegura la reproducibilidad milimétrica de los experimentos criptográficos y la consistencia en el decaimiento simulado o la selección de bases.
- **errors:** Define una semántica sólida de control de flujo en la totalidad del código fuente. Mediante el uso de tipos propios de Rust, este módulo intercepta preventivamente violaciones de las leyes de la mecánica cuántica, segmentándolas en categorías específicas: `StateError` (errores asociados al estado de un sistema físico), `GateError` (errores asociados a las puertas cuánticas), `ChannelError` (asociados a canales cuánticos) y `MeasurementError` (asociado a las mediciones cuánticas). Estas barreras de seguridad resguardan la integridad física de las simulaciones.

IV-G. Protocols

La conjunción de las estructuras previamente descritas posibilita la existencia del módulo `protocols`, el cual alberga las orquestaciones explícitas de interacciones criptográficas entre múltiples actores (típicamente Alice, Bob y un adversario Eve) bajo diversos escenarios de amenaza.

El diseño de `qcrypto` incluye implementaciones de referencia de protocolos de QKD, abarcando esquemas de preparación y medida como el BB84 [11], así como protocolos basados puramente en entrelazamiento como el BBM92 [12]. Además, implementa esquemas criptográficos avanzados como un protocolo interactivo de Pruebas de Conocimiento Nulo Cuánticas para la Autenticación Cuántica de Identidad [13].

Un hito particular en la capacidad de simulación de `qcrypto` radica en su implementación del protocolo B92 [14]. La mayoría de los simuladores enfocados en la evolución de vectores de estado puros hallan severas limitaciones para representar de forma nativa la técnica de Discriminación Inequívoca de Estados, la cual es mandataria para alcanzar la máxima eficiencia teórica del esquema. Gracias a que `qcrypto` modela medidas generalizadas a través del módulo `Measurement`, ha sido factible programar y ejecutar de forma directa el conjunto explícito de operadores POVM óptimos:

$$\begin{aligned} E_1 &\equiv \frac{\sqrt{2}}{1 + \sqrt{2}} |1\rangle \langle 1|, \\ E_2 &\equiv \frac{\sqrt{2}}{1 + \sqrt{2}} \frac{(|0\rangle - |1\rangle)(\langle 0| - \langle 1|)}{2}, \\ E_3 &\equiv I - E_1 - E_2. \end{aligned} \quad (20)$$

Esto permite resolver analíticamente la ambigüedad entre los dos estados no ortogonales del B92, procesando adecuadamente los resultados no concluyentes y obteniendo una tasa de cribado que iguala los márgenes teóricos idóneos, una funcionalidad rara vez expuesta de manera intuitiva en herramientas de simulación.

IV-H. Caso de Uso: Simulación de Protocolos y Análisis Estadístico

Para ilustrar la aplicabilidad de `qcrypto` en entornos de investigación empírica, resulta fundamental demostrar su capacidad para orquestar simulaciones masivas y facilitar la extracción de datos de manera automatizada. El diseño modular de la librería permite a los investigadores programar pruebas de estrés sobre los protocolos criptográficos variando parámetros ambientales, como el nivel de ruido, sin necesidad de modificar el código subyacente de las primitivas.

A continuación, en la Figura 1, se expone un ejemplo práctico donde se muestra como se haría una simulación masiva del protocolo BB84. El experimento itera sobre un arreglo de diferentes configuraciones de ruido (`noise_levels`) inyectadas a través de un canal depolarizante. Para garantizar la solidez estadística del análisis, el sistema ejecuta múltiples iteraciones independientes (`num_executions`) por cada configuración de ruido. En cada ejecución, el método `bb84::run()` procesa todo el protocolo de manera transparente, lo que permite extraer directamente métricas críticas como la Tasa de Error de Bits Cuánticos (QBER) y la longitud final de la clave establecida. Luego se escriben los datos de la experimentación en un archivo csv.

Este ejemplo muestra que `qcrypto` se ha creado teniendo en cuenta la legibilidad del código. No es necesario que un usuario entienda exactamente como funciona Rust para poder entender que hace el código anterior.

V. MÉTRICAS

Para evaluar la eficiencia computacional y la escalabilidad de `qcrypto`, se ha diseñado una batería de pruebas de estrés orientadas a medir el tiempo de ejecución de las operaciones del motor de simulación. Dado que la librería fundamenta su arquitectura en matrices de densidad (ρ), la complejidad espacial y temporal intrínseca es superior a la de los simuladores de vectores de estado. Sin embargo, los resultados demuestran cómo la implementación nativa en Rust y la paralelización de operaciones logran mantener los tiempos de ejecución en márgenes altamente competitivos para la investigación criptográfica.

V-A. Evolución Unitaria del Sistema

La primera evaluación mide el coste temporal de aplicar operaciones unitarias locales sobre un estado global expandido, variando el tamaño del sistema desde $N = 2$ hasta $N = 12$ cúbits. Se han evaluado tres compuertas representativas por su nivel de complejidad: Hadamard (1 cúbit), CNOT (2 cúbits) y Toffoli (3 cúbits).

Tal y como se observa en la Figura 2 de resultados, el tiempo de ejecución, representado en escala logarítmica, dibuja una tendencia lineal a medida que crece el número de cúbits. Este comportamiento refleja la complejidad

Simulación del protocolo BB84 bajo ruido depolarizante

```
use qcrypto::protocols::qkd::bb84;
use qcrypto::QuantumChannel;
use std::fs::File;
use std::io::Write;

fn main() -> Result<(), Box<dyn std::error::Error>> {
    let num_qubits = 1024;
    let eve_ratio = 0.0;
    let check_ratio = 0.2;
    let num_executions = 100;

    let noise_levels = [0.0, 0.05, 0.10, 0.15];

    // Create a CSV file for output
    let mut file_path = File::create("bb84_results.csv")?;
    writeln!(file, "Noise,Execution,QBER,EstablishedKeyLength")?;

    // Iterate over different noise configurations
    for &noise in &noise_levels {
        let channel = QuantumChannel::depolarizing(noise)?;

        // Run the protocol multiple times for each configuration
        for execution in 1..=num_executions {
            let result = bb84::run(num_qubits, &channel, eve_ratio, check_ratio)?;

            // Write the extracted data to the CSV
            writeln!(file_path, "{:.2},{},{:.2},{}", noise, execution, result.qber, result.established_key.len())?;
        }
    }
    Ok(())
}
```

Figura 1. Simulación del protocolo BB84 bajo ruido depolarizante

exponencial teórica esperada $\mathcal{O}(2^{2N})$ para el uso matrices de densidad. No obstante, gracias a las rutinas internas `apply_local_right()` y `apply_local_left()` (transformaciones tensoriales locales) el motor de la librería evita operar con la matriz identidad completa cuando no es estrictamente necesario, logrando que sistemas de hasta 10 cúbits resuelvan sus transformaciones unitarias en tiempos del orden de decenas de milisegundos, manteniendo la viabilidad para la simulación de protocolos de QKD de longitud media.

V-B. Aplicación de Canales de Ruido

El modelado de ecosistemas reales requiere la aplicación de canales cuánticos que introducen decoherencia y errores. Esta operación es computacionalmente más exigente que la evolución unitaria, ya que la representación de Kraus de un canal $\mathcal{E}(\rho) = \sum_k E_k \rho E_k^\dagger$ requiere múltiples multiplicaciones matriciales por cada operador E_k .




Figura 2. Tiempo de aplicación de puertas cuánticas.

La evaluación, que se puede observar en la Figura 3, compara el impacto temporal de un canal discreto (*Bit-Flip*) frente a un canal continuo asimétrico (Amortiguación de Fase y Amplitud, representado como *PAD*). Los resultados muestran que, si bien la sobrecarga computacional es inherentemente mayor frente a las compuertas lógicas, ambas curvas de rendimiento mantienen una pendiente predecible y contenida. Cabe destacar que para sistemas de pocos cúbits, de 2 a 4 cúbits, que suelen ser los más usados en protocolos criptográficos cuánticos, la aplicación de canales de ruido conllevan menos de 0.1 ms, impactando de manera prácticamente despreciable.




Figura 3. Tiempo de aplicación de canales de ruido.

V-C. Muestreo Estadístico Masivo

La simulación de protocolos criptográficos rara vez se limita a una única ejecución; requiere la validación empírica sobre miles o millones de observaciones para trazar con

exactitud la Tasa de Error de Bits Cuánticos (QBER) o la probabilidad de éxito de un adversario.

En la prueba de rendimiento del módulo `Sampler`, Figura 4, se evaluó el tiempo necesario para realizar hasta $2 \cdot 10^6$ mediciones sobre sistemas de 4 y 8 cúbits. A diferencia de la complejidad exponencial observada en la modificación de la matriz de densidad, la gráfica de muestreo revela un escalado estrictamente lineal con respecto al número de muestras.

Este comportamiento se debe al diseño arquitectónico del colapso de estado en `qcrypto`. La librería calcula la Función de Distribución Acumulada del vector diagonal de la matriz una única vez; posteriormente, el módulo `rng` derivado de Rust genera números pseudoaleatorios criptográficamente seguros para emular los colapsos sin incurrir en repetidas multiplicaciones matriciales. De este modo, la simulación de 2 millones de muestras en un sistema de 8 cúbits se resuelve en apenas ≈ 23 milisegundos, garantizando un alto rendimiento para la investigación estadística masiva.




Figura 4. Tiempo de muestreo para distintos estados cuánticos.

VI. CONCLUSIONES Y TRABAJOS FUTUROS

El desarrollo de `qcrypto` proporciona a la comunidad científica una herramienta de investigación robusta, eficiente y matemáticamente rigurosa, diseñada específicamente para simplificar la transición de los conceptos teóricos de la criptografía cuántica hacia la obtención de resultados empíricos verificables. Al basar su arquitectura en el formalismo de matrices de densidad y en medidas generalizadas incluyendo POVMs, la biblioteca permite a los investigadores modelar con precisión sistemas cuánticos abiertos y evaluar el impacto real del ruido y la decoherencia en los canales de comunicación. Esta capacidad es esencial para evaluar la viabilidad práctica y la seguridad de las primitivas criptográficas antes de su implementación física. Asimismo, su implementación nativa en Rust garantiza que las simulaciones masivas y los análisis estadísticos se ejecuten con un alto rendimiento, seguridad de memoria y absoluta reproducibilidad, superando las limitaciones tradicionales de los simuladores cuánticos de propósito general.

Para trabajos futuros, se buscará implementar distintas primitivas criptográficas, como el compromiso cuántico de bits, un componente fundamental para el cálculo multipartito seguro [15]; y la transferencia cuántica inconsciente, que permite al remitente transferir una de varias piezas de información al destinatario, quien puede elegir cuál recibir, sin que el remitente sepa cuál ha sido elegida [16]. Además, se buscará implementar el Lanzamiento Cuántico de Monedas, un protocolo para lograr la equidad en una disputa entre dos partes [17], y Firmas Digitales Cuánticas, que ofrece propiedades de seguridad informática que superan las que se pueden lograr con los protocolos clásicos [18]. También se desarrollará una herramienta CLI basada en `qcrypto` para la experimentación por línea de comandos de todos los protocolos implementados de una manera eficiente y sencilla para el usuario, permitiendo obtener datos sintéticos de calidad de ejecuciones de protocolos criptográficos cuánticos.

AGRADECIMIENTOS

La presente publicación ha sido posible gracias a la Cátedra Binter en Ciberseguridad de la Universidad de La Laguna y a los proyectos de investigación PID2022-138933OB-I00 ATQUE y 2023DIG28 IACTA financiados por MCI-N/AEI/10.13039/501100011033/FEDER EU, y la Fundación CajaCanarias “la Caixa”, respectivamente.

REFERENCIAS

- [1] P. W. Shor, “Polynomial-time algorithms for prime factorization and discrete logarithms on a quantum computer,” *SIAM Journal on Computing*, vol. 26, no. 5, p. 1484–1509, 1997.
- [2] R. L. Rivest, A. Shamir, and L. Adleman, “A method for obtaining digital signatures and public-key cryptosystems,” *Communications of the ACM*, vol. 21, no. 2, p. 120–126, 1978.
- [3] T. Vidick and J. Watrous, “Quantum proofs,” *Foundations and Trends in Theoretical Computer Science*, vol. 11, no. 1–2, p. 1–215, 2016. [Online]. Available: <http://dx.doi.org/10.1561/04000000068>
- [4] J. Garcia-Diaz and D. Escanez-Exposito, “qcrypto,” Feb. 2026. [Online]. Available: <https://github.com/jorgegardiaz/qcrypto>
- [5] S. Klabnik and C. Nichols, *The Rust programming language*. No Starch Press, 2023.
- [6] A. Javadi-Abhari, M. Treinish, K. Krsulich, C. J. Wood, J. Lishman, J. Gacon, S. Martiel, P. D. Nation, L. S. Bishop, A. W. Cross, B. R. Johnson, and J. M. Gambetta, “Quantum computing with Qiskit,” 2024.
- [7] Cirq Developers, “Cirq,” Aug. 2025. [Online]. Available: <https://github.com/quantumlib/Cirq>
- [8] J. Johansson, P. Nation, and F. Nori, “QuTiP: An open-source Python framework for the dynamics of open quantum systems,” *Computer Physics Communications*, vol. 183, no. 8, pp. 1760–1772, aug 2012. [Online]. Available: <https://doi.org/10.1016/j.cpc.2012.02.021>
- [9] LiaoChinTe, “netsquid-simulation,” 2021, accessed 2026-02-28. [Online]. Available: <https://github.com/LiaoChinTe/netsquid-simulation>
- [10] SeQUeNCe, “Sequence,” 2020, accessed 2026-02-28. [Online]. Available: <https://github.com/sequence-toolbox/SeQUeNCe>
- [11] C. H. Bennett and G. Brassard, “Quantum cryptography: Public key distribution and coin tossing,” *Theoretical Computer Science*, vol. 560, pp. 7–11, 2014, theoretical Aspects of Quantum Cryptography – celebrating 30 years of BB84.
- [12] C. H. Bennett, G. Brassard, and N. D. Mermin, “Quantum cryptography without bell’s theorem,” *Phys. Rev. Lett.*, vol. 68, pp. 557–559, Feb 1992. [Online]. Available: <https://link.aps.org/doi/10.1103/PhysRevLett.68.557>
- [13] J. Garcia-Diaz, D. Escanez-Exposito, P. Caballero-Gil, and J. Molina-Gil, “Conjugate coding based designated verifier quantum zero knowledge proof for user authentication,” *Cryptography and Communications*, Apr. 2026. [Online]. Available: <https://doi.org/10.1007/s12095-026-00878-y>
- [14] C. H. Bennett, “Quantum cryptography using any two nonorthogonal states,” *Phys. Rev. Lett.*, vol. 68, pp. 3121–3124, May 1992. [Online]. Available: <https://link.aps.org/doi/10.1103/PhysRevLett.68.3121>
- [15] G. Brassard and C. Crépeau, “Quantum bit commitment and coin tossing protocols,” in *Conference on the Theory and Application of Cryptography*. Springer, 1990, pp. 49–61.
- [16] C. H. Bennett, G. Brassard, C. Crépeau, and M.-H. Skubiszewska, “Practical quantum oblivious transfer,” in *Annual international cryptography conference*. Springer, 1991, pp. 351–366.
- [17] A. Ambainis, “A new protocol and lower bounds for quantum coin flipping,” in *Proceedings of the thirty-third annual ACM symposium on Theory of computing*, 2001, pp. 134–142.
- [18] D. Gottesman and I. Chuang, “Quantum digital signatures,” *arXiv preprint quant-ph/0105032*, 2001.

PQCryptoRefactorer: Pipeline verificado para migración poscuántica asistida por LLMs en repositorios reales

 Javier Pallarés de Bonrosto

Departamento de Informática
Universidad Carlos III de Madrid
Computer Security (COSEC) Lab
javier.pallaresbonrosto@alumnos.uc3m.es

 Ana I. González-Tablas

Departamento de Informática
Universidad Carlos III de Madrid
Computer Security (COSEC) Lab
aigonzal@inf.uc3m.es

Resumen—La reciente estandarización de herramientas de criptografía poscuántica ha convertido la migración de sistemas en una prioridad operativa. Sin embargo, en repositorios reales, la sustitución de primitivas vulnerables enfrenta desafíos de cohesión estructural y dependencias multi-archivo. Este artículo presenta PQCRYPTOREFACTORER, un pipeline híbrido que automatiza la migración en entornos Python mediante el uso de modelos de lenguaje grandes (LLMs). El sistema integra análisis estático para el inventario criptográfico, un modelo especializado ajustado mediante *fine-tuning* para la transformación de código, y un mecanismo de verificación incremental basado en puertas de verificación. Además, el sistema incluye el uso de varios modelos generalistas para la reparación de código y la resolución del impacto multi-archivo y ruptura de contratos. La evaluación en seis repositorios de código abierto, incluyendo CPython y Pip, demuestra una tasa de aceptación del 78,3 % de los parches propuestos, bajo criterios estrictos de validación. Los resultados subrayan la importancia de tratar la migración como una refactorización semántica distribuida para preservar la integridad de los sistemas.

Index Terms—Criptografía poscuántica (PQC), Agilidad criptográfica, Modelos de Lenguaje Grandes (LLMs), Refactorización de software, Análisis estático, Automatización de la seguridad

Tipo de contribución: Investigación en desarrollo (límite 8 páginas)

I. INTRODUCCIÓN

La estandarización de criptografía resistente a adversarios con capacidad cuántica ha pasado de ser un debate académico a un objetivo de transición operativo. En agosto de 2024, NIST publicó los primeros estándares finales de criptografía poscuántica, incluyendo el mecanismo de encapsulación de claves ML-KEM (FIPS 203), e instó a iniciar la transición cuanto antes [1], [2]. En paralelo, iniciativas de adopción como CNSA 2.0 en entornos de alta seguridad refuerzan la necesidad de planificar migraciones con horizonte de varios años [3]. Este contexto ha intensificado el interés en la *agilidad criptográfica*: la capacidad de reemplazar algoritmos y parámetros sin interrumpir sistemas en producción [4].

Sin embargo, migrar criptografía *vulnerable ante adversario cuántico* (*quantum-vulnerable*) en repositorios reales rara vez consiste en reemplazar unas pocas líneas. Las primitivas se entrelazan con imports, gestión de claves, serialización, contratos de funciones y dependencias entre módulos. Como resultado, la migración automática es un problema de *refactorización semántica distribuida*: cambios correctos a nivel

de archivo pueden romper el sistema por impactos multi-archivo (p.ej., variaciones de API, formatos, o expectativas de llamada). Este riesgo es especialmente crítico cuando la cobertura de pruebas es parcial o inexistente, impidiendo detectar regresiones de forma fiable.

Los modelos de lenguaje grandes (LLMs) han mostrado un potencial notable para la transformación de código, y los modelos *fine-tuned* pueden aprender patrones de migración específicos. No obstante, su rendimiento depende fuertemente de la distribución de entrada y del contexto disponible: cuando la migración se realiza por fragmentos limitados, es frecuente omitir información necesaria (imports, inicialización, propagación de cambios) y producir modificaciones inconsistentes. Además, trabajos recientes muestran que la corrección funcional del código generado por LLMs puede estar sobreestimada si los conjuntos de pruebas son insuficientes, lo que subraya la necesidad de verificación automática dentro del proceso de generación [5].

En este artículo proponemos un pipeline híbrido y controlado para migración poscuántica en repositorios Python que integra: (i) análisis estático y de dependencias para detectar usos de criptografía *quantum-vulnerable*, (ii) migración especializada a nivel de archivo mediante un modelo *fine-tuned* alineado con el patrón *archivo*→*archivo*, y (iii) un mecanismo explícito para detectar y gestionar impactos multiarchivo mediante refactorización guiada y verificaciones automáticas. El objetivo no es únicamente generar código poscuántico, sino integrarlo en un proceso que preserve coherencia estructural, estabilidad de interfaz y trazabilidad de resultados.

Las contribuciones principales son:

- Formulamos la migración poscuántica automática en repositorios como un problema de **refactorización semántica distribuida**, más allá del reemplazo local de primitivas.
- Diseñamos e implementamos PQCRYPTOREFACTORER, un **pipeline** que combina inventario criptográfico, migración *archivo*→*archivo* con modelo *fine-tuned*, y gestión explícita del impacto multiarchivo con verificación y *reversión de cambios*.
- Proponemos un esquema de verificación basado en **puertas de verificación** (*gates*) y reparación iterativa orientado a minimizar regresiones estructurales en ausencia de baterías de pruebas completas.

El resto del artículo se organiza como sigue: la Sección II describe la motivación y requisitos del problema en repositorios reales; la Sección III presenta el pipeline propuesto; la Sección IV expone la evaluación y el análisis de fallos; y la Sección V discute limitaciones y trabajo futuro. Finalmente, la Sección VI analiza los trabajos relacionados y la Sección VII las conclusiones.

II. MOTIVACIÓN Y REQUISITOS DEL PROBLEMA

La guía pública más reciente de NIST para la transición a criptografía poscuántica enfatiza que el cambio no se limita a seleccionar algoritmos, sino que implica planificación, inventario y sustitución progresiva de componentes dentro de productos y servicios [6]. En paralelo, NIST enmarca la *agilidad criptográfica* como la capacidad organizativa y técnica de reemplazar algoritmos y parámetros con impacto mínimo, resaltando la necesidad de estrategias que reduzcan acoplamientos y faciliten migraciones repetidas [7]. En repositorios software reales, estos principios se enfrentan a un obstáculo práctico: el uso criptográfico suele estar distribuido y acoplado a decisiones de arquitectura y a contratos internos, por lo que una migración *correcta* en un punto puede causar roturas en múltiples ubicaciones dependientes.

II-A. De sustituciones locales a refactorización semántica distribuida

En un repositorio típico, la criptografía afecta de forma transversal a:

- **Dependencias e imports:** cambios de librerías, módulos y nombres importados.
- **Gestión de claves:** generación, almacenamiento, carga y formatos de clave.
- **Serialización e interoperabilidad:** codificaciones (p.ej., hex/base64), estructuras de mensajes y compatibilidad entre componentes.
- **Contratos de interfaz:** firmas de funciones, clases, tipos esperados y excepciones.
- **Protocolos internos:** pasos de *handshake*, derivación de claves y acuerdos de formato entre módulos.

Por tanto, la migración automática no debe tratarse como un reemplazo local de primitivas, sino como una *refactorización semántica distribuida*: el sistema debe mantener coherencia estructural y de interfaz mientras modifica un subconjunto de archivos y componentes.

II-B. Señales imperfectas: inventario y verificación en repositorios reales

Dos hechos condicionan el diseño de cualquier enfoque automatizado. Primero, el inventario mediante análisis estático es esencial para localizar candidatos y priorizar cambios, pero sus salidas pueden contener falsos positivos/negativos y deben interpretarse como señales para guiar la migración y la revisión. La literatura reciente muestra que herramientas SAST presentan limitaciones importantes en entornos realistas y que su rendimiento depende de configuración y contexto [8]. Segundo, en repositorios con cobertura de tests limitada, la ausencia de una batería completa obliga a introducir mecanismos alternativos de validación (p.ej., compilación por archivo, validaciones estructurales y puertas de verificación) para reducir el riesgo de regresiones silenciosas.

II-C. Requisitos de diseño

A partir de lo anterior, derivamos requisitos prácticos para un pipeline de migración poscuántica asistido por LLMs en repositorios:

- **R1: Trazabilidad y determinismo operativo.** Cada cambio debe vincularse a un hallazgo y conservar evidencia persistida: entradas (código objetivo y contexto del lote), indicaciones (*prompts*) y configuración de modelo, parches generados y decisiones (verificación, reparación, aceptación o reversión).
- **R2: Granularidad controlada.** La unidad de migración debe permitir cambios localizados sin perder contexto crítico (equilibrio entre archivo completo y fragmentos).
- **R3: Preservación de contratos.** El proceso debe detectar impactos de interfaz y gestionarlos explícitamente para evitar roturas multiarchivo.
- **R4: Verificación incremental.** Deben aplicarse *puertas* automáticas (sintaxis/compilación¹, reducción de hallazgos, consistencia de codificaciones) antes de aceptar un parche.
- **R5: Reparación y reversión.** El sistema debe poder reintentar, escalar contexto/modelo y revertir cambios si aparecen degradaciones estructurales.
- **R6: Coste controlado.** Debe instrumentarse el coste/tiempo por fase, establecer un presupuesto máximo por repositorio y limitar el número de intentos para mantener escalabilidad. En la implementación actual se fija un umbral de gasto por repositorio y se registra telemetría básica de consumo para facilitar mediciones posteriores.

Estos requisitos motivan el pipeline híbrido propuesto en la Sección III, donde integramos inventario estático, migración especializada a nivel de archivo con un modelo ajustado a la tarea, y mecanismos explícitos de gestión de impacto multiarchivo con verificación y reparación iterativa.

III. PIPELINE PROPUESTO: MIGRACIÓN VERIFICADA Y CONTROLADA

El sistema PQCRYPTOREFACTORER aborda la migración poscuántica como un proceso de transformación *verificada*, no como una única generación de código. La arquitectura se organiza como un orquestador por fases que integra (i) inventario estático y extracción de dependencias para localizar usos criptográficos relevantes, (ii) migración guiada por un modelo ajustado a la tarea sobre unidades de trabajo trazables, y (iii) mecanismos explícitos de verificación, reparación e integración multiarchivo para reducir el riesgo de regresión (véase la Figura 1).

Modelos utilizados por fase. El núcleo de migración utiliza un modelo *especializado*: **GPT-4.1-mini** ajustado mediante *supervised fine-tuning* para la migración de primitivas criptográficas implementadas con la librería `pyca/cryptography` [11]. El ajuste se realiza con ejemplos emparejados de código pre- y poscuántico y se alinea con

¹ Aunque Python se describe habitualmente como un lenguaje interpretado, su proceso de ejecución requiere una fase previa de compilación a *bytecode*. En este trabajo, el término “errores de compilación” hace referencia a los errores sintácticos detectados por el intérprete durante esta fase de análisis estático (por ejemplo, al generar el Árbol de Sintaxis Abstracta mediante `ast.parse`), los cuales impiden la ejecución del código.




Figura 1. Descripción gráfica de PQCRYPTOREFACTORER

el patrón *archivo*→*archivo*, de modo que el modelo captura transformaciones completas cuando dispone del contexto adecuado. Para tareas auxiliares orientadas a consistencia global del repositorio se emplean modelos *generalistas*: **gpt-5-mini** se usa para refactorizar consumidores cuando se detectan cambios de interfaz, y **o4-mini** se utiliza para pulido final. Esta separación especialista/generalista reduce riesgo y coste: el modelo ajustado se reserva para transformaciones criptográficas sensibles, mientras que los modelos generalistas se emplean para tareas de integración y mantenimiento del repositorio.

III-A. Inventario y contextualización del riesgo

La primera fase construye un inventario del uso criptográfico del repositorio y extrae señales suficientes para guiar la migración. Para ello se emplea *Semgrep* [9] con un conjunto de reglas específicas y se complementa con un análisis de dependencias que permite identificar librerías criptográficas utilizadas. Cuando procede, se genera además un SBOM mediante *CycloneDX* [10] a partir de dependencias declaradas. Las salidas se normalizan para el orquestador y se almacenan como artefactos persistidos (principalmente CSV para hallazgos/dependencias y JSON para hallazgos crudos y SBOM), de forma que la selección de objetivos sea reproducible. Tras el escaneo, se filtran hallazgos para centrarse en los casos críticos accionables y descartar señales informativas fuera del alcance de migración. En este trabajo, se considera crítico únicamente aquello que pertenece a categorías cubiertas por el modelo de migración ajustado y su distribución de entrenamiento [11]. Dentro de ese subconjunto, se retienen los hallazgos que representan uso directo de primitivas criptográficas (p.ej., instancias de cifrado, firma digital o intercambio de claves) y se descartan tres tipos de señales: (1) importaciones de librerías criptográficas, por ser meramente informativas; (2) configuraciones de protocolos de transporte (TLS/SSL), que requieren intervenciones a nivel de infraestructura fuera del alcance de una transformación de código; y (3) hallazgos de categoría no resuelta. Adicionalmente, las primitivas de *hash* se tratan como implícitas cuando acompañan a una categoría primaria en el mismo fichero, evitando duplicidad en la migración.

III-B. Unidad de trabajo: lote semántico y granularidad controlada

El núcleo del pipeline es la unidad de migración denominada lote (*bundle*). En primer lugar, los hallazgos producidos por *Semgrep* se agrupan por clave lógica (archivo, categoría y primitiva), formando unidades semánticas de migración. Sobre cada grupo, se realiza análisis sintáctico mediante árboles de sintaxis abstracta (AST) [13] para: (i) localizar la función, clase o asignación que contiene el hallazgo; (ii) extraer de forma precisa el bloque de código objetivo; y (iii) identificar los puntos de invocación (*call-sites*) en los que dicho bloque es utilizado, información necesaria en fases posteriores de integración multiarchivo. Los lotes se materializan como artefactos JSON persistidos (uno por lote) facilitando trazabilidad y re-ejecución controlada.

III-C. Transformación principal con modelo especializado (GPT-4.1-mini fine-tuned)

La migración principal se realiza con **GPT-4.1-mini** ajustado mediante *fine-tuning* [11]. La entrada al modelo incluye (i) la categoría de migración y (ii) el código pre-cuántico asociado al lote, siguiendo un formato estable alineado con la distribución de entrenamiento. El resultado del modelo se sanea para eliminar texto no-código y se aplica directamente sobre el archivo objetivo del lote en la copia de trabajo del repositorio. A continuación, el cambio se somete al conjunto de puertas de verificación (Sección III-D). El parche se persiste como diff unificado en formato PATCH [12] y se asocia a metadatos de ejecución en el resumen del repositorio

III-D. Verificación incremental mediante puertas de verificación

Antes de aceptar un cambio, el pipeline aplica una política de *puertas de verificación* como criterio mínimo de calidad. En la configuración actual se emplean tres comprobaciones: (1) compilación sintáctica del archivo modificado (mediante *ast.parse*), (2) reescaneo estático del archivo modificado para comprobar que el patrón criptográfico objetivo desaparece, y (3) chequeos semánticos de consistencia en codificaciones de claves/artefactos (p.ej., detección de patrones problemáticos en el tratamiento de claves en crudo).

Si un lote no supera estas puertas, el sistema entra en el bucle de reparación y vuelve a ejecutar las mismas comprobaciones tras cada intento. En el flujo estándar de fallo de puertas, el archivo objetivo *no se revierte inmediatamente*: el contenido generado puede mantenerse durante los reintentos y solo se restaura al contenido original si se agotan todos los intentos sin superar las puertas. Los resultados se almacenan como *informes de verificación* en JSON por lote.

III-E. Reparación iterativa, escalado de contexto y preservación estructural

Si un lote no supera las puertas de verificación, el sistema activa un bucle de reparación con un número máximo de intentos. En cada intento se regenera el código incorporando el error observado en la verificación previa, se vuelve a aplicar el cambio al archivo objetivo y se ejecutan de nuevo las mismas puertas de verificación. En el último intento, si el lote estaba configurado en modo SNIPPET, el proceso puede escalar el contexto a `WHOLE_FILE` para proporcionar al modelo el archivo completo y reducir fallos por falta de contexto.

Para mitigar un modo de fallo típico en modelos generativos (colapso estructural del módulo, como eliminar clases/funciones y reemplazarlas por un bloque mínimo), se aplica una guarda de preservación estructural basada en comparación de definiciones *top-level*. Si la guarda falla, el sistema revierte de forma inmediata el archivo objetivo a su contenido original, registra el fallo estructural como una verificación fallida y entra igualmente en el ciclo de reparación. Fuera de este caso, la reversión definitiva del archivo al contenido original solo se realiza cuando se agotan todos los intentos de reparación sin éxito. El diagnóstico y el historial de intentos quedan integrados en el *informe de verificación* por lote.

III-F. Impacto multiarchivo y refactorización de consumidores (gpt-5-mini)

Una transformación local puede modificar contratos (nombres, firmas o formatos) y provocar incoherencias en módulos dependientes. Para tratar esta dimensión distribuida, el pipeline genera un *paquete de impacto* por lote que incluye (i) un manifiesto de cambios de interfaz y (ii) un mapa de archivos potencialmente afectados por referencias. La fase de refactorización multiarchivo se ejecuta solo si se detecta al menos un lote con cambio de interfaz (equivalentemente, si existe algún lote con `api_preserved=False`).

La refactorización se aplica archivo a archivo sobre los consumidores afectados utilizando **gpt-5-mini**. Para cada archivo consumidor, se escribe el contenido refactorizado y se ejecuta inmediatamente una comprobación sintáctica local; si falla, ese archivo se revierte a su contenido original y se registra el fallo. Los resultados se agregan en un *informe de refactorización*.

III-G. Pulido final (o4-mini) y pruebas

Tras la refactorización, se aplica una fase de pulido con **o4-mini** para resolver problemas de integración de baja complejidad (imports faltantes o sobrantes, nombres indefinidos e incoherencias menores). Esta fase opera sobre una lista deduplicada de archivos realmente modificados por la migración

(*migrated_files*): si varios lotes afectan al mismo archivo, se pule una única vez.

El pulido es conservador: para cada archivo candidato, el sistema propone una versión pulida y ejecuta un *compile-check* antes de escribir. Si la versión pulida no compila, no se aplica y se conserva el contenido original, registrando el motivo (p.ej., `compile_error`); si no mejora el diagnóstico, también se evita aplicar el cambio (`no_improvement`). Los resultados se registran en el *informe de pulido*.

III-H. Aplicación de cambios y trazabilidad del proceso

El sistema opera sobre una copia de trabajo del repositorio objetivo y aplica cambios incrementales para posibilitar verificación. En la fase de migración por lote, el cambio se aplica al archivo objetivo antes de verificar; si tras agotar los intentos el lote falla, el archivo se revierte a su estado original. En las fases multiarchivo (refactorización y pulido), los cambios se validan por archivo y se revierten o se descartan de forma local cuando no superan la comprobación sintáctica.

En paralelo, el pipeline persiste artefactos y resúmenes por repositorio: inventario (CSV/JSON), lotes (JSON), parches (PATCH) e informes (JSON) de verificación por lote, impacto, refactorización, pulido y pruebas, junto con un resumen consolidado (*informe final*). Esta separación permite auditar decisiones y reproducir la evaluación sin mezclar artefactos experimentales con el árbol de código del repositorio.

III-I. Alineación de requisitos con mecanismos del proceso

El diseño del pipeline se construye explícitamente para satisfacer los requisitos de la Sección II. En particular: (R1) se garantiza mediante persistencia de entradas, indicaciones, parches e informes de decisión por lote; (R2) mediante la construcción de lotes con granularidad controlada (archivo completo o fragmento) a partir del inventario; (R3) mediante el paquete de impacto y la refactorización de consumidores cuando se detectan cambios de interfaz; (R4) mediante puertas de verificación aplicadas antes de aceptar una migración; (R5) mediante un bucle de reparación acotado y reversión automática ante fallos o degradaciones estructurales; y (R6) mediante presupuestos y límites de intentos por fase para mantener escalabilidad.

IV. EVALUACIÓN

Esta sección evalúa en qué medida el proceso satisface los requisitos técnicos definidos en la Sección II (R1–R6) y la eficacia preliminar del sistema propuesto. La evaluación se limita a hechos verificables en artefactos persistidos del sistema y evita inferencias no justificadas sobre corrección funcional completa, dada la disponibilidad desigual de baterías de pruebas en repositorios reales.

IV-A. Metodología, unidad de análisis y fuente de verdad

La unidad de evaluación es el *lote* de migración: un cambio sobre un archivo o un grupo de cambios relacionados. Para cada lote se toma el estado final de verificación: si hubo reintentos, se considera el último resultado; en caso contrario, el resultado directo. La fuente de verdad son los informes por lote y los resúmenes de verificación persistidos; no se emplean contadores históricos inconsistentes cuando entran en conflicto con el estado final por lote.

La evaluación se realiza sobre seis repositorios *open-source* en Python (cpython, pip, snappass, prefect, python-jose y alexa-sdk), clonados en local para ejecutar el pipeline sobre el código real. La selección busca cubrir escenarios heterogéneos en tamaño y estilo de código: desde proyectos pequeños (p.ej., python-jose, 6.226 LOC) hasta repositorios de gran escala (p.ej., cpython, 2.597.401 LOC), incluyendo tamaños intermedios como pip (151.010 LOC) y prefect (1.022.932 LOC). Asimismo, se asume una disponibilidad desigual de baterías de pruebas, condición frecuente en repositorios reales y relevante para interpretar la verificación alcanzada.

IV-B. R1: Trazabilidad y determinismo operativo

Evidencia evaluada. Para cada lote, el sistema persiste la entrada operativa (bloque objetivo y contexto asociado al lote), el parche aplicado y la decisión final, junto con los informes de verificación (incluyendo el historial de reparación cuando aplica) y el análisis de impacto. En la ejecución del modelo se registran metadatos de trazabilidad (identificador del lote y del modelo, contadores de tokens, coste estimado, estado de éxito/error) y el *código generado* resultante.

Resultado observado. La evaluación se apoya precisamente en estos artefactos persistidos para reconstruir decisiones de aceptación/no aceptación y diagnósticos (por ejemplo, errores de sintaxis con fichero y línea). Esto permite auditar el proceso sin depender de contadores agregados no verificables.

IV-C. R2: Granularidad controlada

Evidencia evaluada. La unidad de decisión es el lote, lo que permite aplicar y evaluar cambios acotados, en lugar de reescrituras monolíticas del repositorio.

Resultado observado. Los resultados se expresan por repositorio como conteos de lotes aceptados/no aceptados, y las causas de rechazo se asocian a lotes concretos. Esta granularidad permite aislar fallos (p.ej., un `SyntaxError` en un módulo) sin invalidar el resto de migraciones del repositorio.

IV-D. R3: Preservación de contratos e integración multiarchivo

Evidencia evaluada. Para capturar la dimensión distribuida, se consideran (i) rupturas de interfaz detectadas y (ii) archivos potencialmente afectados por referencias a símbolos impactados. En el proceso, una ruptura de interfaz se registra cuando el análisis de impacto identifica cambios en símbolos expuestos y referencias potenciales en otros archivos. Cuando existen cambios explícitos, se listan símbolos concretos.

Resultado observado. La Tabla I resume estas señales. Se observan casos con cambio explícito de símbolos (prefect: `_get_fernet_encryption`, `encrypt_fernet`, `decrypt_fernet`; cpython: símbolos como `HMAC`, `digest`, `new` en `Lib/hmac.py`). También se observan repositorios donde el alcance potencial es alto incluso con pocos lotes (por ejemplo, snappass con 73 archivos potencialmente afectados), lo que respalda la necesidad de tratar la migración como refactorización distribuida.

Tabla I
RESULTADOS POR REPOSITORIO. “RUPTURAS DE INTERFAZ” INDICA LOTES DONDE SE DETECTA CAMBIO DE CONTRATO; “ARCHIVOS POTENCIALMENTE AFECTADOS” CUANTIFICA REFERENCIAS DETECTADAS A SÍMBOLOS IMPACTADOS.

Repositorio	Lotes	Acept.	No acept.	Rupt. interfaz	Arch. afectados
cpython	10	7	3	2	101
pip	7	5	2	0	42
snappass	1	1	0	0	73
prefect	1	1	0	1	2
python-jose	3	3	0	3	0
alexa-sdk	1	1	0	0	0

IV-E. R4: Verificación incremental y criterio de aceptación

Evidencia evaluada. Un lote se considera aceptado únicamente si supera la verificación de las tres puertas (compilación sintáctica, reescaneo estático y chequeos de codificación de claves) tras la migración y, en su caso, tras el ciclo de reparación (hasta el número máximo de intentos). En caso contrario, el lote se descarta para integración y el archivo objetivo se revierte a su contenido original.

Resultado observado. En la muestra analizada se evaluaron 23 lotes. De ellos, 18 lotes fueron aceptados y 5 no aceptados, lo que corresponde a una tasa de aceptación observada del 78,3 %. Este resultado cuantifica la eficacia operativa bajo un criterio estricto: no se integra ningún lote sin una verificación positiva. La verificación es *incremental* porque se ejecuta lote a lote durante la fase de migración, sin esperar a completar el resto de lotes o fases posteriores; el *pulido final* se aplica después sobre archivos ya asociados a lotes aceptados y no constituye una puerta de aceptación del lote.

IV-F. R5: Reparación y reversión

Evidencia evaluada. Cuando un lote no supera las puertas de verificación, el proceso permite reintentos mediante el ciclo de reparación. Si, tras agotar los intentos, el lote continúa fallando, se marca como no aceptado y el archivo objetivo se revierte a su contenido original; por diseño, no se integra.

Resultado observado. Los cinco lotes no aceptados quedan explicados por causas técnicas observables en la verificación final:

- Errores de sintaxis (3 casos) en cpython: literales de cadena sin cerrar en `hmac.py` (línea 157) y `imaplib.py` (línea 117), y un paréntesis sin cerrar en `multiprocessing/connection.py` (línea 133).
- Fallo de compilación con diagnóstico no específico (2 casos) en pip: dos lotes fallan la comprobación de compilación tras reintentos de reparación en `utils/headers.py` y `requests/auth.py`. En estos casos, la salida de la compilación no aporta un detalle accionable (p.ej., salida truncada), lo que limita el análisis causal. De forma destacable, en uno de los lotes el reescaneo estático no detecta hallazgos residuales tras la migración, pero el archivo sigue sin superar la compilación, ilustrando que la eliminación del patrón criptográfico no es suficiente si el artefacto final no es sintácticamente válido.

Estos resultados muestran que el proceso evita integrar cambios inválidos y conserva diagnósticos verificables. A su vez,

los casos con diagnóstico no específico delimitan una mejora concreta: enriquecer la instrumentación de compilación para convertir fallos genéricos en errores accionables.

IV-G. R6: Coste controlado (estado actual).

En esta versión no se ha realizado todavía una medición precisa y comparativa de costes por repositorio. No obstante, el proceso incorpora un umbral de gasto configurado en 5 USD por repositorio para acotar el riesgo económico durante las ejecuciones. En las ejecuciones realizadas, el coste observado se sitúa en el orden de 0.5–1 USD por repositorio como estimación preliminar, si bien este rango no debe interpretarse como una medida definitiva. Para obtener una medición realista y reproducible será necesario realizar varias ejecuciones controladas con configuración fija, contabilizar de forma homogénea el consumo por fase (incluyendo reintentos y escalados de modelo), y reportar estadísticas agregadas sobre un conjunto de repositorios más amplio y representativo.

IV-H. Resumen de la evaluación

En conjunto, el pipeline acepta 18 de 23 lotes evaluados (78,3 %) bajo el criterio estricto de verificación por lote (tres puertas tras migración y, en su caso, reparación). A nivel de repositorio, cuatro proyectos alcanzan migración completa bajo este criterio (todos los lotes aceptados: `alex-sdk`, `snappass`, `prefect` y `python-jose`), mientras que dos quedan en migración parcial por lotes rechazados (`pip` y `cpython`). Las fases posteriores de integración (*refactor* y *polish*) operan sobre el estado resultante de los lotes aceptados/revertidos y generan artefactos de auditoría adicionales; no obstante, no modifican el criterio de aceptación del lote, sino que buscan reducir incoherencias de integración cuando existen consumidores o problemas menores de código.

En repositorios con cambios de interfaz, la corrección de consumidores depende de que existan referencias localizables dentro del árbol analizado: por ejemplo, en `python-jose` no se detectan consumidores locales, mientras que en `prefect` se detectan referencias pero los ficheros no aparecen en el alcance del clon analizado, por lo que la refactorización se omite.

La auditoría se apoya en artefactos persistidos por lote y por repositorio, que permiten reconstruir qué se cambió, por qué se aceptó/rechazó y qué efectos potenciales se identificaron en las dependencias.

V. DISCUSIÓN Y TRABAJO FUTURO

V-A. Qué aportan los resultados desde una perspectiva de ingeniería

Los resultados de la Sección IV respaldan una lectura práctica: el valor del enfoque no depende únicamente de la capacidad de un modelo para proponer cambios, sino de integrar esa generación en un proceso que *delimita* qué migraciones pueden pasar a integración y cuáles deben descartarse. El criterio de aceptación basado en verificación final por lote aporta una frontera operativa clara: cuando una migración falla, no se incorpora; cuando se acepta, queda acompañada de trazabilidad y evidencias observables (p.ej., símbolos modificados y alcance potencial del impacto). Este planteamiento es especialmente relevante en repositorios reales, donde la

Tabla II
RELACIÓN ENTRE REQUISITOS (SECCIÓN II) Y EVIDENCIA VERIFICABLE EMPLEADA EN LA EVALUACIÓN.

Req.	Evidencia evaluada	Artefacto verificable
R1	Entradas, parche y decisión final por lote.	Informe por lote
R2	Decisión por cambios acotados (lotes) con granularidad controlada.	Descripción del lote
R3	Cambios de interfaz y alcance potencial (símbolos y referencias).	Paquete de impacto
R4	Aceptación estricta por verificación final positiva.	Lote aceptado
R5	Reintentos y descarte final si no se valida.	Informes de verificación
R6	Presupuesto máximo por repositorio (5 USD) y telemetría de consumo para estimación preliminar (0.5–1 USD).	Informe final (coste)

cobertura de pruebas suele ser incompleta y una integración sin guardas puede introducir regresiones silenciosas.

Además, la evaluación refuerza la tesis de refactorización distribuida. El hecho de que en ciertos repositorios se observen muchos archivos potencialmente afectados incluso con pocos lotes sugiere que el riesgo principal no es el cambio local, sino su compatibilidad con dependencias y contratos internos. En este contexto, la separación entre (i) migración focalizada del objetivo criptográfico y (ii) gestión explícita del impacto en el resto del repositorio resulta un diseño natural para reducir riesgo y controlar el alcance.

V-B. Implicaciones para la migración poscuántica en repositorios reales

Desde un punto de vista de adopción, el sistema se alinea con necesidades habituales de agilidad criptográfica: identificar dónde aparece criptografía heredada, migrar de forma incremental, y mantener capacidad de auditar qué se cambió y por qué. La estructura por lotes facilita una estrategia conservadora: aplicar migraciones de forma progresiva, inspeccionar las que afectan a símbolos o presentan impacto amplio, y reservar intervención manual para casos que el proceso rechaza por verificación o para cambios con consecuencias arquitectónicas.

Asimismo, la concentración de rechazos finales en errores de sintaxis o fallos de compilación poco diagnósticos sugiere que, al menos en esta muestra, las barreras principales para integración automática no son necesariamente decisiones criptográficas complejas, sino la robustez del parche final y la calidad del diagnóstico de verificación. En términos de ingeniería, esto abre una vía de mejora muy concreta: fortalecer las etapas que garantizan *validez del artefacto* (sintaxis/compilación) y mejorar telemetría para que los rechazos sean inmediatamente accionables.

V-C. Limitaciones y trabajo futuro

Aunque la muestra cubre seis repositorios concretos y no pretende ser representativa del ecosistema completo, el trabajo continúa para ampliar repositorios y mejorar la fidelidad estadística. Además, la validación funcional depende de baterías de pruebas disponibles; por ello, la evaluación se centra en aceptación estricta por verificación final y diagnósticos técnicos observables. Como trabajo en curso, se está mejorando

la instrumentación de la evaluación (para evitar discrepancias entre ejecuciones y enriquecer diagnósticos de compilación) y se están refinando métricas de integración para caracterizar con mayor precisión el impacto distribuido en repositorios de mayor escala.

El trabajo continúa en cuatro direcciones principales:

- **Ampliación del estudio empírico.** Incrementar el número de repositorios y diversificar dominios y estilos de código para obtener resultados más representativos y robustos, manteniendo el mismo criterio de aceptación basado en verificación final.
- **Mejora de métricas e instrumentación.** Consolidar una instrumentación homogénea que evite discrepancias entre ejecuciones y permita métricas comparables por repositorio y por categoría (p. ej., tasa de aceptación por tipo de migración, estabilidad de símbolos, y efecto de cada fase).
- **Diagnóstico de verificación más explicativo.** Aumentar la granularidad de los diagnósticos de compilación y de las causas de rechazo para convertir fallos no específicos en errores accionables, reduciendo el número de reintentos y el coste de depuración.
- **Validación funcional reforzada.** Integrar estrategias de verificación complementarias cuando los repositorios no disponen de tests (p. ej., pruebas mínimas generadas, invariantes por módulo o validaciones de comportamiento sobre entradas controladas), de forma que la aceptación no dependa únicamente de sintaxis/compilación en escenarios sin pruebas.

En conjunto, estos pasos buscan transformar una evaluación inicial en un marco más completo y fidedigno, con un conjunto de repositorios mayor y métricas de integración más precisas, manteniendo el principio central del enfoque: aceptar únicamente migraciones que superen validaciones técnicas explícitas y trazables.

VI. TRABAJOS RELACIONADOS

La migración a la criptografía poscuántica (PQC) se reconoce cada vez más como un desafío distribuido de ingeniería de software en lugar de una simple sustitución de librerías [16], [19]. Los marcos actuales categorizan la transición en cuatro fases: diagnóstico, planificación, ejecución y mantenimiento [19]. Un aspecto crítico de esta transición es la gestión de las interdependencias arquitectónicas; Hasan et al. [23] proponen un marco centrado en el análisis de dependencias de seguridad para mitigar los riesgos durante el reemplazo de primitivas. Para apoyar este análisis, se han desarrollado herramientas para el inventario automatizado y la generación de *Cryptography Bill of Materials (CBOM)* mediante análisis estático y expresiones regulares [15], [20], [21].

El uso de modelos de lenguaje grandes (LLMs) ha mostrado un gran potencial para automatizar cambios a nivel de código a gran escala. Google reportó una migración masiva exitosa para el cambio de tamaño de tipos de datos utilizando LLMs [18], mientras que revisiones generales destacan la eficacia de los LLMs en la reparación de vulnerabilidades y la refactorización [14], [17]. Sin embargo, los enfoques existentes a menudo pasan por alto la visión “QSSE” (*Quantum-Safe Software Engineering*), que requiere gestionar restricciones no

funcionales como el aumento del tamaño de las claves y la resistencia a ataques de canal lateral [16], [22].

Nuestra investigación se basa en un modelo de migración especializado desarrollado y evaluado previamente en [11], en el que se propone y evalúa un modelo LLM *fine-tuned* para migrar primitivas Python. PQCRYPTOREFACTORER avanza el estado del arte al operacionalizar la gestión de dependencias de seguridad y la agilidad criptográfica mediante un pipeline automatizado y verificado que mitiga los riesgos de la refactorización en sistemas distribuidos. Al combinar un modelo especialista ajustado para la migración a nivel de archivo ([11]) con modelos generalistas para la reparación de código y la resolución del impacto multi-archivo y ruptura de contratos, en este trabajo abordamos los desafíos semánticos distribuidos que los enfoques manuales o puramente locales previos [21], [23] no permitían escalar.

VII. CONCLUSIONES

La migración poscuántica en repositorios reales no se reduce a sustituir primitivas de forma local: los cambios pueden afectar a contratos internos, símbolos y dependencias entre módulos, convirtiendo el problema en una refactorización distribuida. En este trabajo hemos presentado un proceso de migración asistida por modelo de lenguaje que prioriza la integración segura mediante verificación final estricta por lote y trazabilidad de resultados, de forma que solo se aceptan cambios que superan validaciones técnicas explícitas.

La evaluación inicial en seis repositorios muestra que el enfoque permite aceptar una proporción elevada de migraciones bajo este criterio (78,3% de los lotes), y que los rechazos finales quedan explicados por causas concretas (principalmente errores de sintaxis y fallos de compilación con diagnóstico limitado), evitando decisiones subjetivas. Estos hallazgos refuerzan que el valor práctico del sistema reside tanto en generar parches como en delimitar con evidencia qué cambios pueden integrarse y cuáles deben descartarse.

Como línea inmediata, el trabajo continúa ampliando el número de repositorios y mejorando la instrumentación y las métricas de evaluación, con el objetivo de obtener resultados más representativos y diagnósticos más accionables, así como reforzar la validación funcional cuando no existen baterías de pruebas completas.

AGRADECIMIENTOS

El trabajo de J.P.B. se ha desarrollado gracias a una Beca de Colaboración en Departamentos universitarios para el curso académico 2025-2026, otorgada por el Ministerio de Educación, Formación Profesional y Deportes. Por su parte, el trabajo de A.I.G.-T. ha sido financiado por los proyectos PID2022-140126OB-I00 y PID2023-150310OB-I00 de la AEI, así como por los proyectos Vital-IoT y APAMciber, financiados por INCIBE (Ministerio para la Transformación Digital y la Función Pública) y los fondos NextGenerationEU de la Unión Europea a través del Plan de Recuperación, Transformación y Resiliencia (PRTR) y el Mecanismo de Recuperación y Resiliencia (RRF). Adicionalmente, el trabajo de ambos autores ha contado con el apoyo de la red de investigación en ciberseguridad EMACS (Proyecto RED2024-123456-T financiado por MICIU/AEI/10.13039/501100011033).

REFERENCIAS

- [1] NIST, “NIST Releases First 3 Finalized Post-Quantum Encryption Standards,” Aug. 2024. [Online]. Available: <https://www.nist.gov/news-events/news/2024/08/nist-releases-first-3-finalized-post-quantum-encryption-standards>
- [2] NIST, *FIPS 203: Module-Lattice-Based Key-Encapsulation Mechanism Standard (ML-KEM)*, Aug. 2024. [Online]. Available: <https://csrc.nist.gov/pubs/fips/203/final>
- [3] National Security Agency (NSA), “NSA Releases Future Quantum-Resistant (QR) Algorithm Requirements for National Security Systems,” Sep. 2022. [Online]. Available: <https://www.nsa.gov/Press-Room/News-Highlights/Article/Article/3148990/nsa-releases-future-quantum-resistant-qr-algorithm-requirements-for-national-se/>
- [4] NIST, “Crypto Agility,” NIST CSRC Project Page, Feb. 2025. [Online]. Available: <https://csrc.nist.gov/projects/crypto-agility>
- [5] J. Liu, C. S. Xia, Y. Wang, and L. Zhang, “Is Your Code Generated by ChatGPT Really Correct? Rigorous Evaluation of Large Language Models for Code Generation,” *NeurIPS*, 2023. [Online]. Available: <https://arxiv.org/abs/2305.01210>
- [6] D. Moody *et al.*, *NIST IR 8547 (Initial Public Draft): Transition to Post-Quantum Cryptography Standards*, NIST, Nov. 2024. [Online]. Available: <https://csrc.nist.gov/pubs/ir/8547/ipd>
- [7] E. Barker, *Considerations for Achieving Crypto Agility: Strategies and Practices (NIST CSWP 39)*, NIST, 2025. [Online]. Available: <https://nvlpubs.nist.gov/nistpubs/CSWP/NIST.CSWP.39.pdf>
- [8] G. Bennett *et al.*, “Semgrep*: Improving the Limited Performance of Static Application Security Testing Tools,” *Proc. ACM*, 2024. [Online]. Available: <https://dl.acm.org/doi/10.1145/3661167.3661262>
- [9] Semgrep Inc., “Semgrep,” 2025. [Online]. Available: <https://semgrep.dev/>
- [10] CycloneDX, “CycloneDX: Software Bill of Materials (SBOM) Standard,” 2025. [Online]. Available: <https://cyclonedx.org/>
- [11] J. Pallarés de Bonrostro, “El Rol de los LLMs para la Agilidad Criptográfica: Migración de Sistemas a Criptografía Poscuántica,” Jun. 2025. Trabajo de Fin de Grado, Grado en Ingeniería Informática, Universidad Carlos III de Madrid.
- [12] J. C. Mogul and J. A. Postel, “The Unified Diff Format,” 2000. [Online]. Available: https://www.gnu.org/software/diffutils/manual/html_node/Unified-Format.html
- [13] Python Software Foundation, “ast — Abstract Syntax Trees,” *Python 3 Documentation*, 2025. [Online]. Available: <https://docs.python.org/3/library/ast.html>
- [14] A. Anand, *et al.*, “A comprehensive survey of AI-driven advancements and techniques in automated program repair and code generation”, 2024. arXiv preprint arXiv:2411.07586.
- [15] M. Moffie, *et al.*, “Cryptoscope: Analyzing cryptographic usages in modern software”, 2025. arXiv preprint arXiv:2503.19531.
- [16] L. Zhang, “Toward Quantum-Safe Software Engineering: A Vision for Post-Quantum Cryptography Migration”, 2026. arXiv preprint arXiv:2602.05759.
- [17] X. Hou, *et al.*, “Large language models for software engineering: A systematic literature review”, 2024. *ACM Transactions on Software Engineering and Methodology*, 33(8), 1-79.
- [18] C. Ziftci, *et al.*, “Migrating code at scale with LLMs at Google”, 2025. In *Proceedings of the 33rd ACM International Conference on the Foundations of Software Engineering* (pp. 162-173).
- [19] C. Näther, *et al.*, “Migrating software systems toward post-quantum cryptography—A systematic literature review”, 2024. *IEEE access*, 12, 132107-132126.
- [20] K. Leirimaa, “Supporting PQC migration and cryptographic agility with automated CBOM generation”, 2024. Master’s Thesis in Information Technology. University of Jyväskylä.
- [21] F. Schröck, “Theoretical and Practical Aspects of the Migration to Post Quantum Cryptography”, 2024. Master Thesis in Computer Science. Leipzig University of Applied Sciences.
- [22] E. Edward, A.S. Nyamawe, & N. Elisa, “A Survey on Secure Refactoring”, 2024. *SN Computer Science*, 5(7), 952.
- [23] F. Hasan, *et al.*, “Migrating to Post-quantum cryptography: A framework using security dependency analysis”, 2023. arXiv preprint arXiv:2307.06520v2.

MASTER-OF-PUPPETS: Framework Agentless de Control Remoto para Operaciones de Ciberseguridad

Antton Rodriguez, Xabier Etxezarreta, Iñaki Garitano, Mikel Iturbe, Urko Zurutuza

Departamento de Electrónica e Informática

Mondragon Unibertsitatea

Goiru 2, E-20500 Arrasate-Mondragón

Email: {arodriguezc,xetxezarreta,igaritano,miturbe,uzurutuza}@mondragon.edu

Resumen—La detección de anomalías y de intrusiones requiere entrenar modelos con conjuntos de datos realistas que incluyan interacción humano-máquina. Sin embargo, la creación de estos datasets está severamente limitada por la dificultad inherente de automatizar operaciones sobre Interfaces Gráficas de Usuario (GUI). Aunque la automatización es un pilar de la ciberseguridad moderna, suele depender de APIs o líneas de comandos. Si bien los Grandes Modelos de Lenguaje (LLM) recientes pueden interpretar interfaces visuales, los frameworks actuales de automatización dependen de la instalación de agentes locales. Para abordar este desafío, presentamos MASTER-OF-PUPPETS, un framework de control remoto agentless para ciberseguridad que desacopla la inteligencia del entorno controlado. Para demostrar su viabilidad, hemos implementado el sistema de control remoto utilizando el estándar Remote Desktop Protocol (RDP), lo que permite observar el estado gráfico del sistema y traducir instrucciones en lenguaje natural a secuencias de teclado y ratón. Al operar exclusivamente a través de la red, el sistema adopta un enfoque estrictamente agentless, sin requerir software adicional en la máquina objetivo. Evaluamos el framework en tres escenarios representativos de ciberseguridad: (i) generación de reglas en un firewall, (ii) reconocimiento de red, y (iii) autenticación web. Los resultados demuestran que MASTER-OF-PUPPETS extiende la automatización agentless y mantiene una alta compatibilidad con prácticas de administración reales. Finalmente, discutimos las implicaciones de seguridad, fiabilidad y control asociadas a estos agentes autónomos.

Index Terms—Control Remoto, Agentless, LLM, Automatización de Ciberseguridad, Interacción con GUI, RDP

Tipo de contribución: *Investigación original.*

I. INTRODUCCIÓN

La automatización se ha convertido en un componente esencial de la ciberseguridad moderna para hacer frente al incremento exponencial en volumen, velocidad y complejidad de los incidentes [1]. En entornos operativos reales, como los Centros de Operaciones de Seguridad (SOC), la capacidad de ejecutar acciones de respuesta de forma rápida, consistente y reproducible es un factor determinante para reducir el impacto de ataques avanzados. En este contexto, las plataformas de orquestación, automatización y respuesta de seguridad han emergido como la solución predominante [2], permitiendo coordinar flujos de trabajo automáticos a partir de eventos de seguridad heterogéneos.

No obstante, el alcance efectivo de estas soluciones sigue estando fuertemente condicionado por la disponibilidad de interfaces programables formales. La mayoría de los mecanis-

mos de automatización actuales asumen que los sistemas objetivo exponen APIs bien definidas o, en su defecto, interfaces de línea de comandos (CLI) accesibles de forma remota [3]. Esta suposición, aunque válida en arquitecturas modernas, no se cumple en una parte sustancial del ecosistema tecnológico real. Sistemas heredados (*legacy*), herramientas de administración de sistemas operativos críticos, aplicaciones industriales y software forense propietario continúan dependiendo casi exclusivamente de Interfaces Gráficas de Usuario (GUI) diseñadas para la interacción humana directa [4].

Esta dependencia de las GUIs introduce una brecha fundamental de automatización. Tareas rutinarias pero críticas —como la configuración manual de políticas de seguridad, la inspección visual de estados del sistema o la interacción con asistentes gráficos— permanecen fuera del alcance de los mecanismos automáticos tradicionales. Esta limitación se ha abordado mediante técnicas de automatización robótica de procesos (RPA), que simulan la interacción humana a nivel de teclado y ratón. Sin embargo, el RPA clásico presenta deficiencias documentadas por Syed et al. [5], destacando su extrema fragilidad frente a cambios mínimos en el diseño o resolución de la interfaz visual.

La aparición reciente de Grandes Modelos de Lenguaje (LLM) ha supuesto un cambio de paradigma en la interacción hombre-máquina, evolucionando de sistemas conversacionales a agentes autónomos capaces de ejecutar tareas complejas [6]. Estos modelos, no solo procesan lenguaje natural, sino que demuestran capacidades emergentes para interpretar interfaces visuales, razonar sobre el estado de la pantalla y planificar decisiones secuenciales, aproximándose al comportamiento de un operador humano [7]. Este avance ha impulsado el desarrollo de agentes diseñados para navegar GUIs de propósito general. Sin embargo, la revisión de la literatura actual indica que la mayoría de las propuestas predominantes (e.g., aquellos evaluados en benchmarks como OSWorld [8] o Mind2Web [9]) dependen de una ejecución local para acceder al árbol de accesibilidad del sistema (DOM, Accessibility API) o requieren la inyección de código para interactuar con los elementos.

En este trabajo presentamos **MASTER-OF-PUPPETS**, un framework de control remoto para operaciones de ciberseguridad que desacopla el razonamiento del entorno controlado mediante el uso de protocolos estándar como único canal de

interacción. Al observar el flujo gráfico y actuar mediante eventos de entrada de bajo nivel (teclado y ratón), el sistema actúa como un operador humano bajo un enfoque estrictamente *agentless*. Esta arquitectura elimina la necesidad de agentes o dependencias adicionales en el sistema objetivo, permitiendo operar en entornos donde la modificación del sistema está restringida. Las principales contribuciones de este trabajo son los siguientes:

- El diseño e implementación de una arquitectura de control remoto *agentless*, capaz de interactuar visualmente con sistemas operativos mediante la capacidad de razonamiento de modelos LLM multimodales.
- La implementación de un mecanismo de traducción que convierte instrucciones de alto nivel expresadas en lenguaje natural en secuencias precisas de eventos de teclado y ratón.
- La evaluación experimental del framework en tres escenarios representativos de operaciones de ciberseguridad sobre el sistema operativo Windows a través del protocolo RDP:
 1. (*defensivo*) configuración de reglas de firewall como tarea típica de administración de sistemas;
 2. (*ofensivo*) reconocimiento de red simulando la fase inicial de un ejercicio de Red Teaming;
 3. (*autenticación*) automatización del proceso de inicio de sesión en un servicio web mediante interacción gráfica.

El resto del artículo está estructurado de la siguiente manera. La Sección II presenta una revisión del estado del arte en automatización de sistemas y agentes de control basados en LLM. La Sección III describe en detalle la arquitectura y los componentes del sistema propuesto. La Sección IV presenta el escenario de pruebas y casos de uso utilizados para la evaluación. La Sección V evalúa el sistema en escenarios operativos de ciberseguridad. La Sección VI discute las limitaciones observadas y consideraciones de seguridad, y finalmente, la Sección VII expone las conclusiones y líneas de trabajo futuro.

II. TRABAJOS RELACIONADOS

La evolución de la automatización en sistemas informáticos ha transitado desde la ejecución de scripts deterministas hasta la reciente aparición de agentes autónomos impulsados por Inteligencia Artificial. En esta sección, clasificamos las soluciones existentes según su paradigma de operación (determinista vs. probabilístico). También analizamos su aplicabilidad en el dominio de la ciberseguridad, destacando las limitaciones que motivan la necesidad de un enfoque como el propuesto en este trabajo. La Tabla I resume esta comparación, evaluando cada solución en base a los siguientes criterios:

Paradigma: Diferencia entre sistemas *Deterministas* (○), regidos por reglas estáticas rígidas (scripts, RPA clásico), y sistemas *Probabilísticos* (●), impulsados por la inferencia dinámica de modelos de IA.

Ejecución: Especifica el entorno o sistema operativo sobre el cual la solución tiene capacidad de control y actuación (p. ej., Windows, Linux, MacOS o Android).

Huella: Mide el nivel de alteración o rastro que deja la solución en el sistema objetivo:

- **Alto (●):** Soluciones que requieren la presencia de binarios, agentes o servicios adicionales en el host.
- **Bajo (○):** La solución opera *Living-off-the-Land*, apoyándose exclusivamente en herramientas administrativas nativas presentes en el sistema operativo (PowerShell, SSH, RDP, etc.).

Soporte: Evalúa la capacidad nativa del sistema para interactuar con GUIs o CLIs:

- **Completo (●):** Interacción nativa y directa.
- **Indirecto (◐):** Soporte de comandos a través de una interfaz gráfica mediadora (p. ej., ejecución de scripts vía GUI).
- **Nulo (○):** Indica que no dispone de soporte.

Dependencias en Objetivo: Indica si la solución requiere la instalación de software adicional, librerías o agentes en el sistema objetivo para su funcionamiento.

II-A. Automatización Determinista y Basada en Reglas

La administración de sistemas ha confiado en herramientas de infraestructura como código (IaC) y gestión de configuración. Soluciones como Ansible [17] representan el estándar en la automatización *agentless* remota, utilizando protocolos como SSH para garantizar la compatibilidad en la configuración de dispositivos. Aunque robustas, estas herramientas son ciegas al entorno gráfico; su utilidad es nula cuando la interacción requiere manipular una GUI o cuando no existen APIs expuestas, una situación común en herramientas forenses propietarias o sistemas legacy.

Para abordar la interacción con interfaces gráficas, surgen herramientas de scripting visual como SikuliX [4], [11] o librerías de automatización de escritorio como AutoIt [10] y PyAutoGUI [12]. Estas soluciones buscan patrones visuales (coincidencia de píxeles) para ejecutar clics y eventos de teclado. Si bien permiten automatizar GUIs, son enfoques frágiles y estrictamente deterministas: un cambio en la resolución de pantalla, el tema de color o la posición de una ventana provoca el fallo inmediato del script, careciendo de la capacidad de recuperación necesaria para operaciones críticas.

II-B. Automatización Probabilística

La llegada de los LLMs ha permitido transicionar de reglas rígidas a sistemas probabilísticos capaces de ver y razonar.

Recientemente, se han propuesto diversos agentes diseñados para operar sistemas operativos completos. Cradle [13] demuestra cómo un modelo LLM puede controlar cualquier aplicación de software mediante capturas de pantalla, actuando como un puente entre la visión y el control de bajo nivel. En paralelo, UFO [14] se especializa en el entorno Windows, utilizando un enfoque de agente dual (uno para observación y otro para acción) para mejorar la precisión en el cambio de aplicaciones.

En el ámbito móvil, AppAgent [18], [20], [21] y BTL-UI [19] han sido pioneros en la navegación de interfaces de Android, aprendiendo a interactuar con aplicaciones mediante gestos simulados. Más recientemente, el benchmark OSWorld [8] ha establecido un estándar para evaluar estos agentes multimodales en tareas de sistema operativo abiertas, evidenciando que, aunque prometedores, la mayoría de estos sistemas asumen una ejecución local. Esta dependencia de la ejecución local implica que el “cerebro” del agente debe

Tabla I
COMPARATIVA DEL ESTADO DEL ARTE EN CONTROL DE SISTEMAS Y CIBERSEGURIDAD.

Entorno	Solución / Framework	Paradigma		Ejecución	Huella	Soporte		Dependencias en Objetivo
		Det.	Prob.			GUI	CLI	
Control Local	AutoIt [10]	●	○	Windows	●	●	●	Runtime de AutoIt
	SikuliX [4], [11]	●	○	Windows, Linux, MacOS	●	●	○	Java y SikuliX instalado
	PyAutoGUI [12]	●	○	Windows, Linux, MacOS	●	●	○	Python y PyAutoGUI instalado
	Cradle [13]	○	●	Windows, Linux, MacOS	●	●	○	Python y dependencias del framework
	UFO [14]	○	●	Windows	●	●	○	Python y dependencias del framework
	PentestGPT [15]	○	●	Windows, Linux, MacOS	●	○	●	Python y dependencias del framework
	AutoAttacker [16]	○	●	Linux	●	○	●	Python y dependencias del framework
Control Remoto	Ansible [17]	●	○	Windows, Linux, MacOS	○	○	●	Servicio SSH/WinRM habilitado
	AppAgent [18], BTL-UI [19]	○	●	Android	○	●	○	ADB / USB debugging activado
	MASTER-OF-PUPPETS (Propuesto)	○	●	Windows	○	●	○	Protocolo RDP

tener acceso directo a las APIs de accesibilidad o al sistema de archivos del objetivo.

II-C. Automatización en Ciberseguridad

En el dominio específico de la seguridad ofensiva y defensiva, la aplicación de LLMs ha comenzado a ganar tracción. Herramientas como PentestGPT [15] asisten a los operadores en pruebas de penetración, guiando el proceso de razonamiento. Sin embargo, PentestGPT opera principalmente como un asistente que sugiere comandos, manteniendo al humano en el bucle para la ejecución final o requiriendo la instalación de entornos de prueba específicos.

Más recientemente, AutoAttacker [16] ha avanzado este paradigma proponiendo un sistema totalmente autónomo que se ejecuta localmente en la máquina del atacante (e.g., sobre Kali Linux). Este agente interactúa directamente con herramientas CLI como Metasploit para lanzar campañas de ataque.

En contraste, nuestra propuesta **MASTER-OF-PUPPETS** ofrece capacidades de agente autónomo visual (como los agentes locales) pero opera estrictamente de forma remota a través de la red (como las herramientas de administración remota), sin dejar huella de software (agentes, Python, o dependencias) en la máquina controlada.

III. ARQUITECTURA DEL SISTEMA

La arquitectura propuesta para **MASTER-OF-PUPPETS** implementa un ciclo de control diseñado para operar sistemas de forma remota y autónoma. El diseño desacopla la lógica de razonamiento de la interacción física, estructurándose en dos fases: *Planificación* y *Ejecución*. La Figura 1 ilustra el flujo de información entre estos módulos, desde la recepción de la instrucción inicial por parte del usuario hasta la verificación de las acciones realizadas de control remoto mediante el protocolo RDP.

III-A. Instrucción (Prompt) del Usuario y de Sistema

El texto de entrada a **MASTER-OF-PUPPETS** no se limita a la solicitud del usuario. Se enriquece mediante una Instrucción del Sistema (*System Prompt*), diseñada para actuar como un mecanismo de control. Dado que los LLMs son probabilísticos por naturaleza, esta instrucción impone restricciones estrictas sobre el formato de salida y delimita formalmente el espacio de acción disponible, asegurando la consistencia en la interacción remota.

Definición del Espacio de Acción: Con el objetivo de reducir la complejidad del espacio de búsqueda y garantizar la consistencia operativa, restringimos al modelo planificador a un conjunto cerrado de tres acciones, diseñadas para cubrir

la totalidad de interacciones necesarias en un entorno de escritorio remoto:

1. **Espera:** Inserción de pausas explícitas (medida en segundos). Esta acción es crítica para la sincronización temporal, permitiendo al agente manejar la latencia de red inherente al protocolo RDP y los tiempos de carga de las aplicaciones.
2. **Teclado:** Inyección de cadenas de texto plano en elementos de la interfaz que poseen el foco activo (e.g., campos de búsqueda, terminales). Esto incluye atajos de teclado para navegación (e.g., Win+R para abrir el cuadro de dialogo de ejecutar).
3. **Visión Click:** A diferencia de los scripts tradicionales que dependen de coordenadas absolutas predefinidas (hardcoded), esta acción toma una descripción textual del objetivo visual. Durante la ejecución, el sistema captura el estado actual de la pantalla, localiza el elemento mediante el modelo de visión y calcula dinámicamente las coordenadas espaciales (x, y) para efectuar el clic. Esto dota al sistema de resiliencia frente a cambios en la resolución o disposición de las ventanas.

Restricción de Formato de Salida: A diferencia de los enfoques conversacionales o de generación de código libre, nuestro sistema impone una estructura de datos rigurosa para la salida del planificador. La instrucción del sistema obliga al modelo a generar exclusivamente un objeto JSON válido para unificar las respuestas del modelo, rechazando cualquier texto explicativo fuera de este formato. Esta estandarización garantiza la interpretabilidad del plan sin necesidad de post-procesamiento, asegurando que el módulo de ejecución reciba instrucciones en un formato conocido.

Finalmente, el prompt de sistema también integra un conjunto de reglas heurísticas de seguridad para guiar la lógica en diferentes escenarios. Estas directrices instruyen al modelo sobre cómo manejar secuencias sensibles, como la interacción con campos de contraseña enmascarados o la inicialización de navegadores, forzando la verificación visual de los elementos antes de cualquier interacción.

III-B. Fase de Planificación

En esta fase, el módulo planificador recibe la instrucción compuesta descrita anteriormente y emplea el modelo de código abierto StepFun¹ como motor de inferencia para generar una lista de acciones a ejecutar en el dispositivo de destino. Este proceso transforma la instrucción de entrada

¹<https://github.com/stepfun-ai/Step-3.5-Flash>




Figura 1. Arquitectura general de MASTER-OF-PUPPETS. El sistema desacopla el razonamiento de alto nivel de la interacción visual, cerrando el bucle mediante verificación visual sobre el protocolo RDP.

en un plan de ejecución estructurado mediante dos etapas: la descomposición de tareas y la generación del plan.

Descomposición de Tareas y Razonamiento: Dado que la calidad del resultado depende directamente de la precisión del prompt, el planificador sigue un proceso estructurado de construcción del mismo antes de generar ninguna acción. Este proceso obliga al modelo a analizar el contexto y la intención del usuario, descomponiendo el objetivo de alto nivel en una secuencia ordenada de sub-objetivos. Esta capacidad permite al sistema adaptarse dinámicamente al estado del entorno. Por ejemplo, si el análisis del contexto visual indica que una aplicación requerida no está visible en pantalla, el planificador inserta dinámicamente pasos de recuperación —como ejecutar una combinación de teclas para abrir el buscador, escribir el nombre de la aplicación y esperar a su aparición— antes de proceder con la lógica principal, asegurando así que se cumpla la precondition necesaria para cada acción.

A modo de ilustración, el siguiente fragmento presenta la instrucción de entrada y el razonamiento generado por el modelo para una tarea de configuración de firewall:

```
{
  "instruction": "Crea una nueva regla en el firewall de Windows con nombre Agente_Test para permitir trafico entrante en el puerto 4444TCP usando PowerShell. Una vez creada la regla, escribe el comando exit para cerrar la consola.",
  "thought_process": "Open PowerShell via Run dialog, confirm window visibility with VISION_CLICK, ensure command line focus, execute firewall rule creation command, wait for completion, then type exit and press enter to close console. Use WAITs for application loading and command execution, and VISION_CLICK to verify UI state and prevent focus assumptions."
}
```

Generación de Plan Estructurado: El resultado de la inferencia es un objeto JSON determinista compuesto por el razonamiento en lenguaje natural y una secuencia de pasos ejecutables. Para garantizar la fiabilidad operativa, cada paso individual dentro de esta secuencia se define mediante una estructura de cuatro atributos obligatorios:

- **Identificador:** Un número secuencial que permite la trazabilidad de errores y el seguimiento del progreso.
- **Tipo de Acción:** La categoría de la operación seleccionada del espacio de acción definido en la Sección III-A (tales como atajos de teclado, escritura de texto, esperas o clics basados en visión).
- **Valor de Entrada:** El parámetro específico necesario para ejecutar la acción, como la cadena de texto a introducir, la tecla a presionar o el tiempo a esperar.
- **Descripción Semántica:** Una breve explicación textual del objetivo del paso que facilita la depuración y la interpretabilidad del plan.

A modo de ilustración, el siguiente fragmento presenta la estructura JSON de un paso de espera de 3 segundos generado por el planificador:

```
{
  "step_id": 10,
  "action_type": "WAIT",
  "input_value": "3.0",
  "target_description": "Wait for command to complete"
}
```

Esta estructura garantiza que el plan sea atómico, de modo que cada paso realice una única función, y estrictamente secuencial, asumiendo que un paso solo se ejecuta si el anterior se completó con éxito. Asimismo, el planificador optimiza la secuencia minimizando el uso de esperas pasivas en favor de verificaciones activas, limitando los tiempos de espera fijos únicamente a transiciones de estado no deterministas, como el arranque en frío de aplicaciones o la carga de servicios.

III-C. Fase de Ejecución

El módulo de ejecución actúa como un cliente externo que interactúa exclusivamente a través del protocolo RDP, garantizando el aislamiento entre el entorno del agente y el sistema operativo manipulado.

Middleware de Traducción de Protocolo: La ejecución del plan se realiza a través de un middleware de intermediación basado en el demonio *guacd* (Guacamole Proxy Dae-

mon)². El sistema expone endpoints de control que reciben las acciones generadas por el planificador y las transcodifica al protocolo estándar RDP. El flujo de datos sigue una secuencia lineal: desde la recepción del plan en formato JSON hasta la transmisión del stream RDP hacia el host de destino.

Maapeo de Acciones a Eventos RDP: Las acciones definidas en el espacio de acción no invocan APIs del sistema operativo, sino que sintetizan eventos de periféricos virtuales:

- **Inyección de Teclado:** Las acciones de teclado se descomponen en secuencias de eventos de presión y liberación de teclas. El servicio *guacd* inyecta estos eventos en el canal de entrada RDP, simulando físicamente la actividad de un teclado hardware conectado al puerto remoto.
- **Interacción con Ratón:** Los eventos de clic basados en visión se procesan a través del modelo UI-TARS-1.5-7B³. Este modelo analiza la imagen del escritorio remoto para localizar el elemento objetivo descrito en la acción. Una vez identificadas las coordenadas espaciales del elemento, el sistema envía un paquete de actualización de estado del ratón al servidor RDP. Esto mueve el cursor virtual del sistema remoto y ejecuta el evento de clic.

Bucle de Percepción Visual: La realimentación visual no se obtiene mediante capturas de pantalla del sistema operativo (lo cual requeriría permisos locales), sino interceptando el flujo de vídeo del protocolo RDP. Cuando el agente requiere observar el estado del sistema, solicita al middleware el renderizado del fotograma gestionado por *guacd*. Esta imagen decodificada se procesa posteriormente para alimentar el modelo de detección visual.

IV. ENTORNO EXPERIMENTAL Y ESCENARIOS

Para validar la viabilidad operativa de **MASTER-OF-PUPPETS** en contextos reales de ciberseguridad, diseñamos una batería de experimentos que abarca tres escenarios representativos en ciberseguridad: configuración defensiva de sistemas (*Hardening*), reconocimiento de red en operaciones ofensivas (*Networking*) y automatización de procesos de autenticación. Esta sección describe la metodología experimental y los escenarios de prueba.

IV-A. Configuración del Entorno de Pruebas

Todos los experimentos se han ejecutado sobre un sistema objetivo Windows 11 IoT Enterprise LTSC accesible mediante RDP sobre una red local aislada. El sistema de control, responsable de ejecutar los componentes LLM y gestionar la conexión RDP, opera en una estación de trabajo Linux con las siguientes características:

- **Modelo LLM de Planificación:** StepFun-3.5-Flash para la generación de planes de acción estructurados.
- **Modelo de Visión:** UI-TARS-1.5-7B para la localización de elementos en la interfaz gráfica y verificación de estados.
- **Cliente RDP:** Cliente RDP *guacd* configurado para permitir la inyección de eventos de teclado y ratón, así como la captura del flujo de vídeo para el procesamiento visual.

²<https://guacamole.apache.org/>

³<https://github.com/bytedance/UI-TARS>

IV-B. Escenarios de Prueba

Escenario A: Hardening (Firewall) se centra en tareas defensivas de administración del sistema, evaluando la capacidad del agente para interactuar con herramientas de línea de comandos dentro del GUI. Se instruye al modelo para que utilice PowerShell con el fin de crear una regla de firewall específica llamada “Agente_Test”, diseñada para permitir tráfico entrante TCP por el puerto 4444, requiriendo que el agente ejecute los comandos precisos y finalice la sesión cerrando la consola correctamente.

Prompt del Usuario: Escenario A

Crea una nueva regla en el firewall de Windows con nombre Agente_Test para permitir tráfico entrante en el puerto 4444 TCP usando PowerShell. Una vez creada la regla, escribe el comando exit para cerrar la consola.

Escenario B: Escaneo de Red simula una fase de reconocimiento u operación ofensiva (Red Teaming), donde se pone a prueba el razonamiento secuencial y la memoria del agente. La tarea exige que el sistema primero identifique su propia dirección IP para determinar el rango de red y, acto seguido, realice un escaneo para descubrir otros dispositivos conectados, con la restricción explícita de mantener la ventana de resultados abierta para permitir la verificación visual por parte del usuario.

Prompt del Usuario: Escenario B

Escanea la red, obtén la información del resto de ordenadores que componen tu red. Previo a comenzar mira cuál es tu IP y cerciórate de hacer el escaneo solamente a tu red. Una vez termines la acción, no cierres la ventana final para que yo vea los resultados.

Escenario C: Autenticación Web evalúa la interacción con interfaces gráficas de terceros (navegadores) y la gestión de credenciales en flujos de autenticación. En esta prueba, el agente debe abrir el navegador Firefox en modo incógnito, navegar hacia una URL específica y, en caso de ser solicitado, completar el formulario de inicio de sesión con el usuario y la contraseña proporcionada, demostrando su capacidad para manejar elementos dinámicos de la web y cerrar la aplicación al finalizar.

Prompt del Usuario: Escenario C

Abre firefox en modo incógnito o privado, despues, ve a la página “<https://kari-conjecturable-lorene.ngrok-free.dev>”. Si te pidiese usuario y contraseña utiliza otuser/password. Cierra la ventana, al terminar.

IV-C. Métricas de Evaluación

Para cada escenario, registramos las siguientes métricas durante la ejecución:

- **Success Rate (SR):** Porcentaje de ejecuciones completadas exitosamente sobre el total de intentos

$$SR = \frac{1}{N} \sum_{i=1}^N \mathbb{I}(e_i) \times 100 \quad (1)$$

donde N es el número total de ejecuciones, e_i representa la ejecución i -ésima, e $\mathbb{I}$ es la función indicadora que devuelve 1 si e_i es exitosa, y 0 en caso contrario.

- **Steps:** Número total de acciones primitivas ejecutadas (Espera, Teclado, Visión Click) durante todo el proceso.
- **Tokens:** Consumo total de tokens en las llamadas a modelos LLM, incluyendo las dos fases (Planificación y Ejecución).
- **Tiempo:** Duración total de la ejecución desde la recepción de la instrucción inicial hasta la finalización del plan (medido en segundos), incluyendo las dos fases (Planificación y Ejecución).

Para mitigar la variabilidad inherente de los LLMs, evaluamos cada escenario mediante $N = 50$ ejecuciones independientes. Reportamos estadísticas descriptivas (media μ , desviación estándar σ , mín/máx) para analizar tanto el rendimiento promedio como la consistencia (tasa de éxito) del sistema.

V. RESULTADOS EXPERIMENTALES

Para evaluar la viabilidad técnica de **MASTER-OF-PUPPETS**, sometimos el framework a una batería experimental compuesta por $N = 50$ ejecuciones independientes para cada uno de los escenarios definidos en la metodología. Los resultados cuantitativos, desglosados por fases de operación (Planificación y Ejecución), se resumen en la Tabla II. A continuación, analizamos el desempeño del sistema en tres dimensiones: eficacia operativa, latencia temporal y coste computacional.

V-A. Eficacia y Tasa de Éxito

El análisis de la Tasa de Éxito (SR) muestra que el agente se desempeña mejor en entornos visuales complejos que en tareas de lógica secuencial.

Administración Directa (Escenario A): La configuración de firewall obtuvo un SR del 79 %. Los fallos residuales se atribuyen principalmente a la dificultad de validar visualmente la salida de texto en la consola.

Razonamiento Secuencial (Escenario B): El escenario de reconocimiento de red presentó el desempeño más bajo (SR del 76.5 %). A diferencia del escenario A (comando único), esta tarea requería retener información en memoria (obtener la IP propia y usarla para definir el rango de escaneo). La mayor desviación estándar en el conteo de pasos ($\sigma = 2,90$) se debe a que el agente de planificación a menudo generaba planes diversos para completar la misma tarea. Esto incrementó la tasa de error acumulado, ya que cada paso adicional introducía una nueva oportunidad de fallo.

Dominio Visual (Escenario C): El sistema alcanzó su máximo rendimiento en la automatización web con un SR del 94 %. Esto se debe a que los modelos de visión modernos (UI-TARS) identifican con gran precisión elementos visuales (campos de texto, botones), permitiendo una navegación robusta y sin fallos.

V-B. Latencia y Tiempos de Ejecución

La latencia total del sistema oscila entre 98.52 segundos y 123.78 segundos, evidenciando que la complejidad de la tarea impacta directamente en el tiempo de inferencia.

Sobrecarga de Planificación en Tareas Lógicas: Es notable que en el Escenario B, la fase de planificación fue la más lenta de todos los grupos ($\mu = 63,78s$), superando incluso al escenario Web ($\mu = 62,79s$). Esto refuerza la hipótesis de que el razonamiento secuencial (encadenar herramientas de red) exige mayor tiempo de generación del plan por parte del LLM planificador que la interpretación visual directa.

Velocidad de Ejecución: La fase de ejecución (movimiento de ratón y teclado) es más rápida en tareas de terminal ($\mu \approx 47 - 58s$) que en tareas web ($\mu \approx 61s$), debido a la menor necesidad de renderizado y carga de elementos gráficos en la interfaz remota.

V-C. Coste Computacional (Análisis de Tokens)

Eficiencia de la Terminal: El Escenario A (Hardening) se mantiene como el más eficiente, con un coste medio total de 21,994 tokens. Esto se debe a que la interacción con la consola es relativamente estática: el modelo solo necesita identificar el prompt y validar la salida textual, lo que limita la cantidad de tokens necesarios para describir el estado visual.

Coste de la Interacción Web: El Escenario C es significativamente más costoso, promediando 35,979 tokens ($\sim 63\%$ más que el escenario A). Este incremento se concentra en la Fase 2 (Ejecución), donde el modelo debe procesar capturas de pantalla para comprender el estado del sistema.

Variabilidad: El Escenario C también muestra la mayor desviación estándar en costes ($\sigma = 6609,73$), lo que refleja la naturaleza dinámica de la web: pop-ups inesperados o tiempos de carga variables pueden obligar al agente a realizar más ciclos de observación-acción, disparando el consumo de tokens.

VI. DISCUSIÓN, LIMITACIONES Y LINEAS FUTURAS

Sensibilidad y Optimización de Prompts: El rendimiento del agente y su capacidad para comprender el entorno están fuertemente condicionados por la estructura de la Instrucción del Sistema (System Prompt) y la claridad de la instrucción del usuario. Aunque actualmente el prompt restringe con éxito el formato de salida y el espacio de acción, una definición genérica puede derivar en interpretaciones subóptimas. Como trabajo futuro, consideramos fundamental investigar técnicas de refinamiento dinámico de prompts, ajustando el nivel de detalle y las reglas heurísticas de seguridad según el contexto operativo para maximizar la precisión del modelo.

Planificación Estática y Falta de Capacidad Reactiva: En su iteración actual, el planificador genera una secuencia completa y estática de acciones a priori. Esto significa que, si una precondition falla durante la fase de ejecución (por ejemplo, un retraso en la carga de una interfaz gráfica que exceda el tiempo de espera programado), el agente carece de capacidad para detenerse, reaccionar o corregir el rumbo, provocando el fallo en cascada del resto del plan. Nuestro objetivo a corto plazo es evolucionar hacia una arquitectura reactiva, implementando un bucle de retroalimentación donde el sistema valide visualmente el éxito de cada acción individual y replanifique dinámicamente en caso de error.

Seguridad y Supervisión: Delegar el control de un protocolo de alto privilegio a un modelo probabilístico implica riesgos de seguridad inherentes, especialmente frente a posibles alucinaciones del modelo. Para que el framework sea

Tabla II
COMPARATIVA DE RENDIMIENTO Y EFICIENCIA POR ESCENARIO: TASA DE ÉXITO (SUCCESS RATE, SR), CONTEO DE PASOS, CONSUMO DE TOKENS Y TIEMPO DE EJECUCIÓN EN FASES DE PLANIFICACIÓN Y EJECUCIÓN ($N = 50$).

Escenarios	SR (%)	Pasos (Steps)				Coste (Tokens)				Tiempo (s)			
		Max	Min	Mean	Stdv	Max	Min	Mean	Stdv	Max	Min	Mean	Stdv
A: Hardening (Firewall)	79 %	15	10	11.56	1.12	18325	18319	21994	3300.24	187.97	64.80	98.52	30.16
Fase 1: Planificación		15	10	11.56	1.12	20406	4660	7797.48	2088.69	143.89	20.63	50.68	29.56
Fase 2: Ejecución		-	-	-	-	31911	11890	14197.25	2323.27	80.27	30.72	47.84	10.32
B: Escaneo de Red	76.5 %	24	7	11.39	2.90	38270	18432	24654.55	4530.19	327.44	74.51	122.69	45.14
Fase 1: Planificación		24	7	11.39	2.90	17170	6863	10590.73	2636.05	110.79	36.32	63.78	18.40
Fase 2: Ejecución		-	-	-	-	26915	9114	14063.82	4158.47	219.69	24.76	58.92	35.83
C: Autenticación Web	94 %	24	12	16.78	1.65	56478	20324	35979.32	6609.73	288.21	77.94	123.78	42.16
Fase 1: Planificación		24	12	16.78	1.65	36725	7041	13186.04	6595.32	215.63	26.03	62.79	38.68
Fase 2: Ejecución		-	-	-	-	26583	8529	22793.28	2475.07	83.35	41.24	60.99	9.27

desplegable en entornos críticos reales, los trabajos futuros deberán contemplar la integración de mecanismos de supervisión y control humano explícito. Esto permitiría requerir la autorización explícita de un operador humano antes de ejecutar acciones destructivas o alteraciones severas.

Entorno Multiagente: Como extensión natural del framework propuesto, se plantea la evolución hacia una arquitectura multiagente en la que múltiples instancias operen de forma coordinada, simulando el comportamiento de distintos perfiles de usuario dentro de un entorno corporativo real. Cada agente encapsularía un conjunto de habilidades diferenciadas permitiendo reproducir patrones de interacción hombre máquina con mayor variabilidad. Esto ampliaría la generación de datasets de comportamiento más representativos del ecosistema empresarial.

Integración Mediante Model Context Protocol (MCP): Con el objetivo de dotar al framework de mayor flexibilidad e interoperabilidad, se propone su adaptación al estándar MCP, que permite abstraer la capa de comunicación entre el orquestador y los modelos subyacentes. La adopción de MCP habilitaría la exposición del framework como un conjunto de herramientas consumibles por agentes externos.

Evaluación Comparativa: Como línea de trabajo prioritaria, se plantea la realización de un estudio comparativo sistemático entre **MASTER-OF-PUPPETS** y los frameworks más representativos del estado del arte, tanto deterministas como probabilísticos. El objetivo es someter a todos los sistemas a una batería de pruebas equivalentes bajo condiciones controladas, evaluando métricas de tasa de éxito, latencia y coste computacional. Esta comparativa permitirá cuantificar objetivamente las ventajas e inconvenientes del paradigma agentless frente a enfoques con mayor huella en el sistema objetivo, así como identificar los escenarios operativos en los que cada aproximación ofrece un mejor equilibrio entre rendimiento y restricciones de despliegue.

VII. CONCLUSIONES

En este trabajo presentamos y validamos **MASTER-OF-PUPPETS**, un framework que demuestra la viabilidad de utilizar Grandes Modelos de Lenguaje multimodales para la automatización remota de operaciones de ciberseguridad bajo un paradigma estrictamente *agentless*. Los resultados obtenidos confirman la capacidad del sistema para traducir instrucciones de lenguaje natural en interacciones precisas de teclado y ratón a través del protocolo RDP, en escenarios de administración defensiva, reconocimiento ofensivo y navega-

ción web. Mediante esta arquitectura cerramos la brecha de automatización en sistemas heredados o propietarios carentes de APIs, ofreciendo una alternativa menos invasiva la cual elimina la necesidad de instrumentación local o inyección de código. Si bien identificamos la latencia y el coste de tokens como desafíos para operaciones, nuestra propuesta establece una base sólida para el despliegue de agentes autónomos capaces de operar en infraestructuras de forma remota.

AGRADECIMIENTOS

Esta publicación es parte del proyecto de I+D+i PLEC2024-011222, financiado por AEI/10.13039/501100011033. Iñaki Garitano, Mikel Iturbe y Urko Zurutuza son miembros del Grupo de Investigación IT1870-26, financiado por el Departamento de Ciencia, Universidades e Innovación del Gobierno Vasco.

REFERENCIAS

- [1] M. Vielberth, F. Böhm, I. Fichtinger, and G. Pernul, "Security operations center: A systematic study and open challenges," vol. 8, 2020, pp. 227 756–227 779.
- [2] C. Islam, M. A. Babar, and S. Nepal, "A multi-vocal review of security orchestration," *ACM Comput. Surv.*, vol. 52, no. 2, Apr. 2019. [Online]. Available: <https://doi.org/10.1145/3305268>
- [3] K. Morris, *Infrastructure as code: Dynamic systems for the cloud age*. 'O'Reilly Media, Inc.", 2025.
- [4] T. Yeh, T.-H. Chang, and R. C. Miller, "Sikuli: using gui screenshots for search and automation," in *Proceedings of the 22nd Annual ACM Symposium on User Interface Software and Technology*, ser. UIST '09. New York, NY, USA: Association for Computing Machinery, 2009, p. 183–192. [Online]. Available: <https://doi.org/10.1145/1622176.1622213>
- [5] R. Syed, S. Suriadi, M. Adams, W. Bandara, S. J. Leemans, C. Ouyang, A. H. ter Hofstede, I. van de Weerd, M. T. Wynn, and H. A. Reijers, "Robotic process automation: Contemporary themes and challenges," *Computers in Industry*, vol. 115, p. 103162, 2020. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0166361519304609>
- [6] Z. Xi, W. Chen, X. Guo, W. He, Y. Ding, B. Hong, M. Zhang, J. Wang, S. Jin, E. Zhou *et al.*, "The rise and potential of large language model based agents: A survey," *Science China Information Sciences*, vol. 68, no. 2, p. 121101, 2025.
- [7] A. Hurst, A. Lerer, A. P. Goucher, A. Perelman, A. Ramesh, A. Clark, A. Ostrow, A. Welihinda, A. Hayes, A. Radford *et al.*, "Gpt-4o system card," *arXiv preprint arXiv:2410.21276*, 2024.
- [8] T. Xie, D. Zhang, J. Chen, X. Li, S. Zhao, R. Cao, T. J. Hua, Z. Cheng, D. Shin, F. Lei, Y. Liu, Y. Xu, S. Zhou, S. Savarese, C. Xiong, V. Zhong, and T. Yu, "Osworld: Benchmarking multimodal agents for open-ended tasks in real computer environments," in *Advances in Neural Information Processing Systems*, A. Globerson, L. Mackey, D. Belgrave, A. Fan, U. Paquet, J. Tomczak, and C. Zhang, Eds., vol. 37. Curran Associates, Inc., 2024, pp. 52 040–52 094. [Online]. Available: https://proceedings.neurips.cc/paper_files/paper/2024/file/5d413e48f84dc61244b6be550f1cd8f5-Paper-Datasets_and_Benchmarks_Track.pdf

- [9] X. Deng, Y. Gu, B. Zheng, S. Chen, S. Stevens, B. Wang, H. Sun, and Y. Su, "Mind2web: Towards a generalist agent for the web," in *Advances in Neural Information Processing Systems*, A. Oh, T. Naumann, A. Globerson, K. Saenko, M. Hardt, and S. Levine, Eds., vol. 36. Curran Associates, Inc., 2023, pp. 28 091–28 114. [Online]. Available: https://proceedings.neurips.cc/paper_files/paper/2023/file/5950bf290a1570ea401bf98882128160-Paper-Datasets_and_Benchmarks.pdf
- [10] J. Bennett and T. A. Team, *AutoIt v3: Microsoft Windows Automation, Configuration and Scripting Language*, 2026, accessed: 2026-02-16. [Online]. Available: <https://www.autoitscript.com/site/autoit/>
- [11] T. Yeh, T.-H. Chang, and R. C. Miller, "Sikulix: Visual automation tool," accessed: 2026-02-08. [Online]. Available: <https://sikulix.com/>
- [12] A. Sweigart, *PyAutoGUI: Cross-platform GUI automation Python module for human beings*, 2026, software version 0.9.54, Accessed: 2026-02-16. [Online]. Available: <https://pyautogui.readthedocs.io/>
- [13] W. Tan, W. Zhang, X. Xu, H. Xia, Z. Ding, B. Li, B. Zhou, J. Yue, J. Jiang, Y. Li *et al.*, "Cradle: Empowering foundation agents towards general computer control," *arXiv preprint arXiv:2403.03186*, 2024.
- [14] C. Zhang, L. Li, S. He, X. Zhang, B. Qiao, S. Qin, M. Ma, Y. Kang, Q. Lin, S. Rajmohan, D. Zhang, and Q. Zhang, "UFO: A UI-focused agent for windows OS interaction," in *Proceedings of the 2025 Conference of the Nations of the Americas Chapter of the Association for Computational Linguistics: Human Language Technologies (Volume 1: Long Papers)*, L. Chiruzzo, A. Ritter, and L. Wang, Eds. Albuquerque, New Mexico: Association for Computational Linguistics, Apr. 2025, pp. 597–622. [Online]. Available: <https://aclanthology.org/2025.naacl-long.26/>
- [15] G. Deng, Y. Liu, V. Mayoral-Vilches, P. Liu, Y. Li, Y. Xu, T. Zhang, Y. Liu, M. Pinzger, and S. Rass, "PentestGPT: Evaluating and harnessing large language models for automated penetration testing," in *33rd USENIX Security Symposium (USENIX Security 24)*. Philadelphia, PA: USENIX Association, August 2024, pp. 847–864. [Online]. Available: <https://www.usenix.org/conference/usenixsecurity24/presentation/deng>
- [16] J. Xu, J. W. Stokes, G. McDonald, X. Bai, D. Marshall, S. Wang, A. Swaminathan, and Z. Li, "Autoattacker: A large language model guided system to implement automatic cyber-attacks," *arXiv preprint arXiv:2403.01038*, 2024.
- [17] Red Hat, Inc. (2024) Ansible: Automation for everyone. [En línea]. Disponible: <https://www.ansible.com>. [Online]. Available: <https://www.ansible.com>
- [18] C. Zhang, Z. Yang, J. Liu, Y. Li, Y. Han, X. Chen, Z. Huang, B. Fu, and G. Yu, "Appagent: Multimodal agents as smartphone users," in *Proceedings of the 2025 CHI Conference on Human Factors in Computing Systems*, ser. CHI '25. New York, NY, USA: Association for Computing Machinery, 2025. [Online]. Available: <https://doi.org/10.1145/3706598.3713600>
- [19] S. Zhang, R. Zhang, P. Fu, S. Wang, J. Yang, X. Du, S. Cui, B. Qin, Y. Huang, Z. Luo, and J. Luan, "Btl-ui: Blink-think-link reasoning model for gui agent," 2025. [Online]. Available: <https://arxiv.org/abs/2509.15566>
- [20] Y. Li, C. Zhang, W. Jiang, W. Yang, B. Fu, P. Cheng, X. Chen, L. Chen, and Y. Wei, "Appagent v2: Advanced agent for flexible mobile interactions," *arXiv preprint arXiv:2408.11824*, 2024.
- [21] Y. Zhao, W. Shi, F. Feng, and X. He, "Appagent-pro: A proactive gui agent system for multidomain information integration and user assistance," in *Proceedings of the 34th ACM International Conference on Information and Knowledge Management*, ser. CIKM '25. New York, NY, USA: Association for Computing Machinery, 2025, p. 6767–6771. [Online]. Available: <https://doi.org/10.1145/3746252.3761473>

(Work in Progress): Towards Automated Phishing Kit Fingerprint Generation for Phishing Detection and Classification

Kevin van Liebergen^{*†}, Srdjan Matic^{*‡} Juan Caballero^{*}

^{*}IMDEA Software Institute

[†]Universidad Politécnica de Madrid

[‡]Universidad Carlos III de Madrid

Abstract—Phishing kits enable attackers to rapidly deploy and manage phishing websites. Phishing kit fingerprints are a promising approach to detect phishing websites built with phishing kits. Such fingerprinting-based detection offers key advantages such as low false positives, attribution to specific kits, and robustness to template changes. However, existing approaches rely on manual fingerprint generation, which does not scale.

This work-in-progress paper presents the current status of our project to build the first automated approach for phishing kit fingerprint generation. Our approach takes as input compressed archives of phishing installations, clusters them by similarity to identify installations likely produced by the same phishing kit, and identifies invariant shared resources within each cluster. From these resources, it generates fingerprints consisting of a resource path, a signature, and a label.

We evaluate our approach on 3,097 phishing installation archives. Our approach identifies 326 clusters, each comprising at least two archives, and generates at least one candidate fingerprint for 98.5% of those clusters, producing 15,473 candidate fingerprints. These preliminary results demonstrate the potential of our automated fingerprint generation to enable phishing detection and classification.

I. INTRODUCTION

Phishing attacks trick victims into disclosing their credentials through phishing websites that mimic popular online services such as banks and payment services. According to the FBI, phishing has been the most commonly victim-reported cybercrime every year in the period 2022-2024 [13]. Phishing is part of 15% of data breaches [44] and credentials stolen through phishing can greatly impact victims. For example, in June 2025, the UK tax collection office reported that over 100,000 taxpayers were hit with £47M in losses due personal information obtained through phishing [27].

Phishing kits are software for easily deploying and managing phishing websites [11], [17], [32], [4], [20]. Phishing kits may be freely available [5], [15], [49], acquired in underground forums [16], [14], and leased in Phishing-as-a-Service (PhaaS) offerings [2]. They lower the entry barrier into phishing, facilitating access to cybercriminals with more limited technical skills. Phishing kits are at the root of phishing attacks, e.g., Barracuda Networks reports that 90% of high-volume phishing campaigns in 2025 leveraged PhaaS kits [2].

A variety of phishing defenses exist such as blocklists [37], [34], [12], machine learning (ML) classifiers using URL and content features [43], structural website analysis [43], [41], and visual similarity detectors [25], [1], [22], [23], [18].

An alternative defense uses fingerprinting [4]. Fingerprinting approaches identify networking software running on a remote host by sending requests to remote hosts and applying a classification function (e.g., a signature) to the responses [10].

Bijmans et al. [4] manually built fingerprints for 10 Dutch phishing kits and applied them on a feed of candidate phishing domains to identify previously unknown phishing websites. Such fingerprinting-based detector has several advantages. First, robust fingerprints have low false positives, a property they share with other signature-based approaches. Second, fingerprints identify the specific phishing kit used to build the phishing website, which is useful to rank phishing kits by prevalence, identifying dominant ones that should be prioritized for analysis, anti-evasion, and attribution. Third, fingerprints can capture the phishing kit functionality, rather than the template used by the phishing website. This is important because advanced phishing kits can impersonate multiple brands and the templates they use may be updated over time. Finally, fingerprints can avoid server-side evasion scripts, although they are still susceptible to server-side cloaking using server directives [32].

One limitation of fingerprints is that they can only identify phishing websites that are similar to previously observed ones. However, limited coverage also affects other defenses such as blocklists and visual-similarity detectors targeting a predefined set of brands. Fingerprints can be used for triage by identifying phishing websites built with widely used kits, while deferring less prevalent kits to more general detectors (e.g., ML-based approaches). While fingerprinting-based defenses can greatly complement existing defenses, manually building fingerprints does not scale to the thousands of phishing installations routinely collected [32], [42].

This work-in-progress paper describes the current status of our ongoing project to build the first automated phishing kit fingerprint generation approach. Our approach takes as input a large number of phishing installations, where each installation contains a compressed archive with the contents of a phishing website. Such archives are routinely collected when attackers incorrectly configure directory permissions in their phishing websites [19], [40]. Our approach first clusters the collected archives by similarity such that similar phishing websites (e.g., built by the same phishing kit) are in the same cluster. For each cluster, our approach identifies the shared resources between the archives and builds a signature for content that remains invariant across installations. Each

fingerprint comprises a resource (e.g., `/img/ex.png`), the MD5 hash of the invariant content returned when accessing that resource, and a label.

To evaluate the potential of our fingerprint generation approach, we apply it to 3,097 archives collected from three datasets [42], [9], [38]. Our approach first clusters the 3,097 archives into 326 clusters, each with at least two archives. Then, it generates fingerprints for those 326 clusters. It generates at least one candidate fingerprint for 321 (98.5%) clusters, for a total of 15,473 candidate fingerprints. We believe that this preliminary evaluation shows the potential of our approach. Still, much work lies ahead to determine which of the candidate fingerprints are robust enough for real use (i.e., do not introduce false positives), to build more advanced signatures, and to deploy the fingerprints for detecting previously unknown phishing websites.

II. OVERVIEW

A *phishing kit* is a software for generating phishing websites. At a minimum, a phishing kit includes one or more website templates, each impersonating a legitimate target service, and scripts to implement functionality such as credential collection, forwarding collected credentials via email or Telegram, and cloaking. It may also include additional content such as a backend service to collect information about the victims that visit the phishing website and instructions to deploy the phishing kit. Phishing kits can be freely available [5], [15], [49], acquired [16], [14], or rented [2]. Similar to other software, phishing kits may evolve over time producing different versions of the same kit.

A phishing kit takes as input user-provided configuration data such as the target service template to be used and the email address or Telegram account to receive the collected credentials. It outputs a phishing website, typically in the form of a compressed archive (e.g., ZIP, RAR) that contains all files needed to deploy the phishing website such as HTML pages, images, and PHP scripts.

The phishing kit user may deploy the archive in one or more websites. When deploying it in a web server, the user may unconsciously leave the archive in a publicly accessible open directory. This situation is not rare, and a number of open-source tools exist that given a phishing website try to identify open directories and download any archives they may store [19], [40]. Those tools produce *phishing installations* (or simply *installations*), where each installation is a pair (URL, Archive) corresponding to a compressed archive containing a phishing website that was collected from the URL. If the phishing website was built using a phishing kit, the archive may only contain a subset of the phishing kit’s contents. For example, it may contain a single template, among all templates the phishing kit supports, and it may not include backend code that may be installed in a different website.

III. DATASETS

We collect phishing installations from three public sources, summarized in Table I. Phishunt [38] is a GitHub project while Leaky Kits [42] and PhiKitA [9] are datasets produced by prior works. Phishunt and PhiKitA provide phishing installations collected from URLs, while Leaky kits collected phishing kits from Telegram channels and phishing installations




Figure 1: Top 10 filetypes in our dataset.

from URLs. For simplicity, we treat phishing kits collected from Telegram as installations without a URL. We remove installations across all sources with encrypted, empty, and invalid archives.

The same archive (identified by its MD5 hash) may have been downloaded from different phishing URLs and may appear in different datasets (211 archives appear in two datasets, 10 in the three datasets). Multiple archives may have been downloaded from different URLs hosted on the same registrable domain. Overall, our dataset comprises 3,760 phishing installations from 2,811 unique URLs, belonging to 2,399 registrable domains, from where 3,097 unique archives were downloaded. We uncompress the archives and count their total and unique (by MD5) files. The archives comprise 379,496 files. Many files are identical due to multiple installations of the same kit and generic files (e.g., there are many empty files) for a total of 206,852 unique files (by MD5 of the content).

For each unique file across all datasets, we obtain the filetype using Magika [24]. Overall, Magika identifies 135 filetypes. The top 10 filetypes cover 90.1% of all files and are illustrated in Figure 1. The most common are *php* (32.7%), *javascript* (24.3%), *html* (6.3%), *png* (6.3%), and *txt* (5.0%).

IV. APPROACH

Our fingerprinting approach is summarized in Figure 2. It comprises two phases: fingerprint generation and fingerprint matching. This paper details our current implementation of the fingerprint generation phase, the fingerprint matching phase is currently under development.

The fingerprint generation phase takes as input phishing installations, clusters them so that similar installations (e.g., those generated by the same phishing kit) are in the same cluster, and automatically builds fingerprints for each cluster. A *fingerprint* is a triple (Resource, Signature, Label). Each cluster may have multiple fingerprints. All generated fingerprints are stored in a database.

The fingerprint matching phase takes as input a domain feed. For each domain in the feed, it iterates over the fingerprints in the database. For each fingerprint, it builds a URL that includes the domain and the fingerprint’s resource and tries to access the URL. If the resource exists, then it applies the fingerprint’s signature on the returned content. If the signature matches, then an installation of the phishing kit captured by the fingerprint has been identified and the domain is assigned the fingerprint’s label.

Dataset	Start	End	Installations	Archives	URLs	Domains	Files	File MD5
Leaky Kits [42]	2021-04-08	2022-07-15	2,172	2,172	1,279	1,035	56,322	29,008
Phishhunt [38]	2020-08-01	2025-06-13	837	646	780	780	81,956	35,051
PhiKitA [36]	2022-06-19	2022-08-08	751	510	751	621	209,978	148,430
All	2020-08-01	2025-06-13	3,760	3,097	2,811	2,399	379,496	206,852

Table I: Dataset summary.




Figure 2: Approach overview. This paper only covers the fingerprint generation phase.

If the input domain feed contains unknown domains or candidate phishing domains (e.g., containing phishing-related keywords), then our fingerprinting approach performs both detection (i.e., determining that the domain hosts a phishing website) and classification (i.e., determining the cluster to which the phishing website belongs). If the input domain feed instead contains known phishing websites (e.g., from phishing blocklists), then our approach only performs classification. The fingerprints can also be used offline to classify an archive collected from a phishing website.

A. Clustering

The goal of the clustering is to identify similar archives, which may have been generated by the same phishing kit. These include archives generated by the same kit version using different configurations (e.g., using different templates) and also those generated by close versions of the same kit without major functionality changes (e.g., consecutive minor versions).

Clustering is fundamental to build robust fingerprints. It allows identifying resources whose content remains the same, or very similar, across different kit configurations and close kit versions. It also allows identifying resources that change due to user-provided configuration data. Configuration-specific resources should be avoided since they would make the fingerprints specific to one configuration, failing to identify installations of the same kit configured differently. For example, by comparing archives generated by the same kit using different templates, we can remove template-specific resources that change depending on the configuration, instead building fingerprints on the shared, template-independent, kit resources.

For clustering the archives, we use the Deep MD5 clustering approach proposed by Britt et al. [6]. The clustering groups archives sharing a high percentage of file MD5s. It comprises two steps. First, the distance between each pair of archives is computed using the DeepMD5 score:

$$score = 0.5 * \frac{|A \cap B|}{|A|} + 0.5 * \frac{|A \cap B|}{|B|}$$

Dataset	Non-Singleton Clusters	Singleton Clusters	Max Size
Leaky Kits	210 (725)	1,447	65
Phishhunt	62 (203)	443	24
PhiKitA	48 (151)	359	33
All	326 (1,128)	1,969	109

Table II: DeepMD5 clustering results. In parenthesis, the number of archives in the non-singleton clusters.

where A and B are the sets of MD5 hashes in each archive. Then, it applies a graph-based clustering algorithm. Each node in the graph corresponds to an archive and an edge is added between two nodes if their DeepMD5 score is above a threshold. After building the graph, each connected component corresponds to a cluster. This graph-based clustering approach is equivalent to performing an agglomerative single-linkage clustering. We use the recommended threshold of 0.8.

Table II shows the DeepMD5 clustering results. When applied to all 3,097 archives, it produces 326 non-singleton clusters (i.e., with multiple archives) and 1,969 singleton clusters (i.e., with a single archive). To avoid overly-specific fingerprints, our approach only builds fingerprints when there are at least two archives in the cluster, i.e., fingerprints are not generated for singleton clusters. Thus, we build fingerprints for 326 clusters, which comprise 1,128 archives, 36.4% of the 3,097 archives.

Among the 326 non-singleton clusters, 98 (30.1%) are cross-dataset, i.e., contain archives from different datasets. Of those, 93 clusters contain archives from two datasets and 5 from the three datasets. Given the different dataset collection periods, this likely indicates that some phishing kits are used over long periods of time.

We manually examine the purity of a small subset of generated clusters to determine if they contain false positives, i.e., unrelated archives were clustered together. Given the agglomerative nature of the graph-based clustering, the risk of false positives is much higher in the largest clusters. Thus, we examine the top 25 clusters (over 5% of all non-singleton clusters). Among those, only the largest cluster (containing 109 archives) is not pure, i.e., comprises archives likely generated by unrelated kits. This happens due to the transitive nature of the single-linkage agglomerative clustering. For example, archives A, B, C, D may end up in the same cluster because A is similar to B, which is similar to C, which is similar to D. But, A and D may not be really similar to each other and should not be in the same cluster. For clusters that are not pure, our approach will likely fail to generate a fingerprint. We examine this in Section IV-B.

Identifying false negatives is hard as we lack ground truth about which archives were generated by the same phishing kit. To identify potential false negatives, once we generate



Figure 3: Two uncompressed archives in the same cluster with identical structure underneath different root folders.

fingerprints for each cluster, we examine if there are multiple clusters with the same fingerprint and whether singleton clusters match any of the generated fingerprints. We describe these results in Section IV-B.

B. Fingerprint Generation

A fingerprint is a triple (Resource, Signature, Label). The fingerprint generation module builds fingerprints for each non-singleton cluster following a three-step process. The first two steps determine the fingerprint’s resource by first identifying the root folder for each archive in the cluster and then identifying shared resources with the same relative path to the root folder across all archives. The third step builds a signature for the shared resource. The fingerprint’s label is the cluster identifier. We detail each step next.

Root folder identification. As illustrated in Figure 3, archives in the same cluster often have similar file and directory structure, but the shared structure may start at different *root folders*. The root folder is the one containing the *index file*. We consider four filenames as potential index files in the following order: `index.php`, `index.html`, `login.php`, and `home.php`. For example, in Figure 3, the root folders are `maxi/xls/excel/` and `excelzz/`, respectively. Root folder differences do not affect the functionality of the phishing websites (e.g., internal links are not broken) because the root folder is provided through configuration options to the Web Server so that it can locate the index file. For example, in the Apache Web server, the root folder should be provided in the `DocumentRoot` configuration option and the name of the index file using `DirectoryIndex` (unless it is the default `index.html`).

Shared resources identification. For each archive in the cluster, all files underneath the root folder are visited extracting both their relative path with respect to the root folder (e.g., `bizmail.php`, `css/styles.css`, `img/logo.png`), and their filetype using `Magika`. We call *shared resources* to relative filepaths appearing in all archives with the same filetype. For example, in Figure 3, all 10 files in each archive have the same relative filepath and filetype. Thus, all 10 are shared resources.

Signature generation. Each shared resource is examined to check whether a signature can be built from the contents of the files at those locations. So far, our approach only builds a simple signature. For any shared resource, whose filetype is not PHP or Python, it computes the MD5 hash of the




Figure 4: Cumulative distribution of fingerprints per cluster.

resource’s contents. If the hash of the resource contents is the same across all archives, it becomes a signature. PHP and Python scripts are ignored because HTTP requests for those resources do not return the script’s code, but the result of running the script. For shared resources with an invariant MD5 hash, a fingerprint is output with the shared resource, the MD5 hash as signature, and the cluster identifier. If the hash is not the same across all files pointed by the shared resource, no fingerprint is produced for that shared resource.

Generated fingerprints. We apply our fingerprint generation approach to the 326 non-singleton clusters. Our approach generates a total of 15,473 candidate fingerprints. It generates at least one candidate fingerprint for 321 (98.5%) clusters. There are only 5 (1.53%) clusters without a candidate fingerprint. One of those has no shared resources; it corresponds to the largest cluster, for which we determined in Section IV-A that it was not pure. This illustrates how incorrect clustering results may prevent the generation of fingerprints. The other four clusters without candidate fingerprints only have PHP shared resources, for which we do not currently generate signatures.

Figure 4 shows the cumulative distribution of candidate fingerprints per cluster. There are 317 (97.24%) clusters for which our approach generates more than one candidate fingerprint and 285 (87.4%) with at least 5. Overall, the median is 21.5 candidate fingerprints per cluster, with a mean of 47.5. The extreme case is one cluster with 1,282 candidate fingerprints. For 98.5% of the clusters, our approach already produces multiple candidate fingerprints. However, the candidate fingerprints still need to be evaluated for false positives, so some candidate fingerprints will be discarded.

Out of the 15,473 candidate fingerprints, there are 1,381 pairs of (Resource, Signature) that appear in multiple clusters and 1,622 singleton clusters that match the generated fingerprints. Manual examination shows a few cases where the fingerprint captures a resource with generic content, e.g., a very simple `robots.txt` file. We are currently designing an automated process to remove such generic candidate fingerprints. Other cases happen because there are multiple clusters that should have been merged and singletons that should have been placed in clusters, but the clustering failed to group them. As a next step, we plan to explore better clustering algorithms.

V. RELATED WORK

We categorize prior works into three areas: phishing kits, phishing websites, and automated fingerprint generation.

Phishing kits. Cova et al. [11] described how phishing kits may send collected email credentials back to the phishing kit developers. Follow-up work by Tejaswi et al. [42] identified a wider range of security flaws that make victim data accessible to adversaries beyond the kit deployers and kit developers. Some works have used honeypots to monitor phishers that exploit vulnerable sites to deploy their phishing websites [45], [17]. Other works have studied phishing kit server-side [32], [48] and client-side [47] cloaking techniques used for evasion. Kondracki et al. [20] investigated man-in-the-middle (MITM) phishing kits, which act as malicious reverse proxies of online services, to extract credentials and session cookies in transit. Lee et al. [21] classified phishing websites based on the type of user interaction.

Most related to our work is research by Bijmans et al. [4] that manually created fingerprints for 10 Dutch phishing kits and applied the fingerprints on a feed of domains to identify phishing websites. Our application is similar but we focus on automating the fingerprint generation process so that it can scale to a large number of clusters (e.g., 326 in this work). Also related are open-source projects that publish YARA rules that, given a phishing installation archive, check if it contains specific directory and file names to classify it into previously observed kits [35]. While our fingerprints can also be applied on collected archives, they are designed to identify and classify live phishing websites. Also, our approach clusters archives prior to fingerprint generation, avoiding overly-specific fingerprints.

Phishing websites. Previous works have developed phishing website detection systems by leveraging a variety of techniques such as ML classifiers using URL and content features [43], structural similarity to previously observed phishing websites [43], [41], and visual similarity with the webpages of online services [25], [1], [22], [23], [18]. Blocklists are a popular defense against phishing [37], [34], [12], so prior work has evaluated their effectiveness [30], [31], [3]. Prior work has also evaluated an alternative defense by training potential victims with simulated phishing campaigns [7]. Another research line characterizes the lifecycle of phishing attacks [33], [26].

Automated fingerprint generation. Fingerprinting approaches that identify networking software running on a remote host [10] can be split into passive (i.e., applying signatures on observed network traffic) [39], [29], and active (i.e., sending requests and applying signatures to their responses) [8], [28], [46]. Our approach builds active fingerprints and differs from previous active approaches in focusing on detecting and classifying phishing websites built with kits. Furthermore, it uses a white-box approach that leverages access to the server-side content and scripts produced by the phishing kits.

VI. FUTURE WORK

This paper has presented the current status of our ongoing project to build a system for automatically generating phishing

kit fingerprints. There are many directions that we plan to explore in the remainder of the project:

- **Fingerprint matching.** We have not yet applied the generated fingerprints to their main goal: detecting phishing kit installations and classifying them by the phishing kit used to generate them. We are currently developing the fingerprint matching module and working towards building a domain feed to which we can apply the fingerprints to identify phishing websites.
- **Fingerprint improvements.** Our preliminary results show that we can already generate candidate fingerprints for 98.5% of clusters. But, our current fingerprint generation approach cannot produce candidate fingerprints for clusters where a shared resource points to similar, but not identical, content and for backend scripts (e.g., PHP, Python). We plan to extend our approach to cover such cases. To cover shared resources that point to similar, but not invariant, content we plan to generate more sophisticated signatures based on the filetype of the resource such as using regular expressions for textual content (e.g., *html*, *txt*, *css*, *xml*, *json*, *markdown*), and perceptual hashes for binary images (e.g., *png*, *jpeg*, *gif*). To produce fingerprints for backend scripts (*php*, *python*) we need to change our shared resource identification to also consider URL parameters.
- **Fingerprint robustness.** It is possible that some of the fingerprints we generate are not specific enough and can introduce false positives. We plan to empirically evaluate the candidate fingerprints eliminating those that introduce false positives, e.g., trigger on benign domains.
- **Fingerprint selection.** Our approach already generates multiple fingerprints for 87.2% of the clusters. For those clusters, we can use all available fingerprints, or only a subset of them. We plan to examine the trade-off of those options in terms of robustness and stealthiness.
- **Clustering.** Our preliminary results show that the DeepMD5 clusters have high precision, i.e., out of the top 25 clusters only the largest was impure, but can suffer from false negatives, i.e., the fingerprints generated from one cluster match other clusters. We plan to investigate other clustering approaches that can increase the recall without sacrificing precision.

ACKNOWLEDGMENTS

This work was partially funded by the Spanish Government MCIN/AEI/10.13039/501100011033/ through grants PID2022-142290OB-I00 (ESPAÑA), PREP2022-000165, CEX2024-001471-M, and RED2024-154240-T (EMACS). Partial support was also provided by the Regional Government of Madrid through grant 2025-T1/COM-36349. The above grants are co-funded by European Union ESF, EIE, FEDER, and NextGeneration funds.

REFERENCES

- [1] S. Abdelnabi, K. Kromholz, and M. Fritz, “VisualPhishNet: Zero-Day Phishing Website Detection by Visual Similarity,” in *ACM SIGSAC Conference on Computer and Communications Security*, 2020.
- [2] Ashok Sakthivel, Barracuda Networks, “Threat Spotlight: How phishing kits evolved in 2025,” January 2026, <https://blog.barracuda.com/2026/01/07/threat-spotlight-phishing-kits-evolved-2025>.

- [3] J. Bayer, S. Maroofi, O. Hureau, A. Duda, and M. Korczynski, "Building a Resilient Domain Whitelist to Enhance Phishing Blacklist Accuracy," in *APWG Symposium on Electronic Crime Research*, 2023.
- [4] H. Bijmans, T. Booi, A. Schwedersky, A. Nedgabat, and R. van Wegberg, "Catching Phishers By Their Bait: Investigating the Dutch Phishing Landscape through Phishing Kit Detection," in *USENIX Security Symposium*, 2021.
- [5] "Black Eye," 2024, <https://github.com/EricksonAtHome/blackeye>.
- [6] J. Britt, B. Wardman, A. Sprague, and G. Warner, "Clustering Potential Phishing Websites Using DeepMD5," in *USENIX Workshop on Large-Scale Exploits and Emergent Threats*, 2012.
- [7] L. Brunken, A. Buckmann, J. Hielscher, and M. A. Sasse, "To Do This Properly, You Need More Resources: The Hidden Costs of Introducing Simulated Phishing Campaigns," in *USENIX Security Symposium*, 2023.
- [8] J. Caballero, S. Venkataraman, P. Poosankam, M. G. Kang, D. Song, and A. Blum, "FiG: Automatic Fingerprint Generation," in *Network and Distributed System Security Symposium*, 2007.
- [9] F. Castaño, E. F. Fernández, R. Alaiz-Rodríguez, and E. Alegre, "Phikita: Phishing kit attacks dataset for phishing websites identification," *IEEE Access*, vol. 11, pp. 40 779–40 789, 2023.
- [10] D. E. Comer and J. C. Lin, "Probing TCP Implementations," in *USENIX Summer*, 1994.
- [11] M. Cova, C. Kruegel, and G. Vigna, "There Is No Free Phish: An Analysis of "Free" and Live Phishing Kits," in *USENIX Workshop on Offensive Technologies*, 2008.
- [12] "The APWG eCrime Exchange," 2024, <https://apwg.org/ecx/>.
- [13] Federal Bureau of Investigation, "2024 Internet Crime Report," April 2025, https://www.ic3.gov/AnnualReport/Reports/2024_IC3Report.pdf.
- [14] Flare, "The Phishing Kits Economy in Cybercrime Markets," January 2026, <https://flare.io/learn/resources/phishing-kits-economy-cybercrime>.
- [15] "gophish," 2024, <https://github.com/gophish/gophish>.
- [16] Group IB, "The use of phishing kits surges by 25% in 2022," May 2023, <https://www.group-ib.com/media-center/press-releases/phishing-kits-2022/>.
- [17] X. Han, N. Kheir, and D. Balzarotti, "Phisheye: Live monitoring of sandboxed phishing kits," in *ACM SIGSAC Conference on Computer and Communications Security*, 2016.
- [18] F. Ji, K. Lee, H. Koo, W. You, E. Choo, H. Kim, and D. Kim, "Evaluating the Effectiveness and Robustness of Visual Similarity-based Phishing Detection Models," in *USENIX Security Symposium*, 2025.
- [19] "Kitphishr," 2024, <https://github.com/cybercdh/kitphishr>.
- [20] B. Kondracki, B. A. Azad, O. Starov, and N. Nikiforakis, "Catching transparent phish: Analyzing and detecting mitm phishing toolkits," in *ACM SIGSAC Conference on Computer and Communications Security*, 2021.
- [21] W. Lee, J. Hur, and D. Kim, "Beneath the Phishing Scripts: A Script-Level Analysis of Phishing Kits and Their Impact on Real-World Phishing Websites," in *ACM Asia Conference on Computer and Communications Security*, 2024.
- [22] Y. Lin, R. Liu, D. M. Divakaran, J. Y. Ng, Q. Z. Chan, Y. Lu, Y. Si, F. Zhang, and J. S. Dong, "Phishpedia: A Hybrid Deep Learning Based Approach to Visually Identify Phishing Webpages," in *USENIX Security Symposium*, 2021.
- [23] R. Liu, Y. Lin, X. Yang, S. H. Ng, D. M. Divakaran, and J. S. Dong, "Inferring Phishing Intention via Webpage Appearance and Dynamics: A Deep Vision Based Approach," in *USENIX Security Symposium*, 2022.
- [24] "Magika file type detection," 2026, <https://github.com/google/magika>.
- [25] E. Medvet, E. Kirda, and C. Kruegel, "Visual-Similarity-Based Phishing Detection," in *International Conference on Security and Privacy in Communication Networks*, 2008.
- [26] G. C. Moura, T. Daniels, M. Bosteels, S. Castro, M. Müller, T. Wabeke, T. van Den Hout, M. Korczyński, and G. Smaragdakis, "Characterizing and Mitigating Phishing Attacks at ccTLD Scale," in *ACM SIGSAC Conference on Computer and Communications Security*, 2024.
- [27] Nadeem Badshah, The Guardian, "100,000 UK taxpayer accounts hit in £47m phishing attack on HMRC," June 2025, https://www.theguardian.com/politics/2025/jun/04/100000-uk-taxpayer-accounts-hit-in-47m-phishing-attack-on-hmrc?utm_source=chatgpt.com.
- [28] A. Nappa, Z. Xu, J. Caballero, and G. Gu, "CyberProbe: Towards Internet-Scale Active Detection of Malicious Servers," in *Network and Distributed System Security Symposium*, 2014.
- [29] J. Newsome, B. Karp, and D. Song, "Polygraph: Automatically Generating signatures for Polymorphic Worms," in *IEEE Symposium on Security and Privacy*, 2005.
- [30] A. Oest, Y. Safaei, A. Doupe, G.-J. Ahn, B. Wardman, and K. Tyers, "PhishFarm: A Scalable Framework for Measuring the Effectiveness of Evasion Techniques against Browser Phishing Blacklists," in *IEEE Symposium on Security and Privacy*, 2019.
- [31] A. Oest, Y. Safaei, P. Zhang, B. Wardman, K. Tyers, Y. Shoshitaishvili, and A. Doupe, "PhishTime: Continuous Longitudinal Measurement of the Effectiveness of Anti-Phishing Blacklists," in *USENIX Security Symposium*, 2020.
- [32] A. Oest, Y. Safei, A. Doupe, G.-J. Ahn, B. Wardman, and G. Warner, "Inside a Phisher's Mind: Understanding the Anti-phishing Ecosystem Through Phishing Kit Analysis," in *APWG Symposium on Electronic Crime Research*, 2018.
- [33] A. Oest, P. Zhang, B. Wardman, E. Nunes, J. Burgis, A. Zand, K. Thomas, A. Doupe, and G.-J. Ahn, "Sunrise to Sunset: Analyzing the End-to-end Life Cycle and Effectiveness of Phishing Attacks at Scale," in *USENIX Security Symposium*, 2020.
- [34] "OpenPhish," 2024, <https://www.openphish.com/>.
- [35] "Phishing Kit Yara Rules," 2024, <https://github.com/t4d/PhishingKit-Yara-Rules>.
- [36] "PhikitA-500," 2023, <https://gvis.unileon.es/datasets-phikita-500/>.
- [37] "PhishTank," 2024, <https://phishtank.org/>.
- [38] "Phishhunt," 2024, <https://phishhunt.io/>.
- [39] S. Singh, C. Estan, G. Varghese, and S. Savage, "Automated Worm Fingerprinting," in *USENIX Symposium on Operating Systems Design and Implementation*, 2004.
- [40] "StalkPhish-OSS," 2026, <https://github.com/t4d/StalkPhish/>.
- [41] S. Tanaka, T. Matsunaka, A. Yamada, and A. Kubota, "Phishing Site Detection using Similarity of Website Structure," in *IEEE Conference on Dependable and Secure Computing*, 2021.
- [42] B. Tejaswi, N. Samarasinghe, S. Pourali, M. Mannan, and A. Youssef, "Leaky Kits: The Increased Risk of Data Exposure from Phishing Kits," in *APWG Symposium on Electronic Crime Research*, 2022.
- [43] K. Tian, S. T. Jan, H. Hu, D. Yao, and G. Wang, "Needle in a Haystack: Tracking Down Elite Phishing Domains in the Wild," in *Internet Measurement Conference*, 2018.
- [44] Verizon, "2025 Data Breach Investigations Report," April 2025, https://www.ic3.gov/AnnualReport/Reports/2024_IC3Report.pdf.
- [45] D. Watson, T. Holz, and S. Mueller, "Know your Enemy: Phishing," 2005, <https://honeynet.onofri.org/papers/phishing/index.html>.
- [46] Z. Xu, A. Nappa, R. Baykov, G. Yang, J. Caballero, and G. Gu, "AutoProbe: Towards Automatic Active Malicious Server Probing Using Dynamic Binary Analysis," in *ACM Conference on Computer and Communication Security*, 2014.
- [47] P. Zhang, A. Oest, H. Cho, Z. Sun, R. Johnson, B. Wardman, S. Sarker, A. Kapravelos, T. Bao, R. Wang *et al.*, "CrawlPhish: Large-Scale Analysis of Client-Side Cloaking Techniques in Phishing," in *IEEE Symposium on Security and Privacy*, 2021.
- [48] P. Zhang, Z. Sun, S. Kyung, H. W. Behrens, Z. L. Basque, H. Cho, A. Oest, R. Wang, T. Bao, Y. Shoshitaishvili *et al.*, "I'm SPARTACUS, No, I'm SPARTACUS: Proactively Protecting Users from Phishing by Intentionally Triggering Cloaking Behavior," in *ACM SIGSAC Conference on Computer and Communications Security*, 2022.
- [49] "Zphisher," 2024, <https://github.com/htr-tech/zphisher>.

Process-Aware High-Interaction Honeypot using Shadow Digital Twins

Mohammadhossein Homaei, Agustín Di Bartolo, Óscar Mogollón-Gutiérrez, Pablo García Rodríguez,
and Andres Caro

Grupo de Ingeniería de Medios
Universidad de Extremadura,
Cáceres, Spain

mhomaein@alumnos.unex.es, {adibartolo, oscarmg, pablogr, andresc}@unex.es

Abstract—High-interaction honeypots are essential for ICS security, but existing solutions lack physical realism, making them easy to detect. This paper proposes Adaptive Shadow Digital Twin (ASDT), a hybrid framework combining Koopman-based state evolution with PINN-constrained LSTM residual correction for gas pipeline systems. By predicting non-linear residuals and injecting adaptive network latency, ASDT mimics the complex dynamics of authentic PLCs. Experimental validation using the HAI dataset demonstrates that ASDT achieves a 94.3% fidelity (R^2) and reduces physics-based constraint violations by an order of magnitude ($> 10\times$) compared to pure data-driven models. In our evaluation, ASDT appears statistically close to real assets, yielding a 53.8% discrimination accuracy (near-random guessing) under the considered classifier. With an inference latency of 3.21 ms on edge hardware, the proposed system meets the real-time operational requirements of critical infrastructure.

Index Terms—Industrial Cybersecurity, Cyber-Physical Systems, High-Interaction Honeypot, Shadow Digital Twin, Physics-Informed Deception

Contribution Type: *Original Research*

I. INTRODUCTION

In recent years, the connection between Operational Technology (OT) and the internet, also known as Industry 4.0, has exposed Industrial Control Systems (ICS) to remote cyber threats [1]. Programmable Logic Controllers (PLCs) are now frequent targets of sophisticated attacks that aim to disrupt critical infrastructures like power grids and water plants [2]. To defend these systems, researchers have developed high-interaction honeypots. These tools act as decoys to trick attackers and collect Cyber Threat Intelligence (CTI) about their methods [3]. While early honeypots were simple, modern solutions try to mimic real industrial protocols to keep hackers engaged for a longer time.

However, current honeypots are easy to detect. Attackers use fingerprinting techniques to distinguish fake devices from real ones [4]. More critically, existing honeypots fail to simulate physical processes (like sensor noise or turbine inertia) accurately. Recent studies show that because these decoys lack realistic physical dynamics, adversaries can easily spot them by observing the unnatural behavior of the system data [5]. This “semantic gap” allows attackers to bypass defenses and target the real assets.

The primary motivation for this research is the critical need for “indistinguishable” decoys. If a honeypot cannot mimic the laws of physics, it is ineffective against a competent enemy. Therefore, the central research question arises: How can we generate real-time, physics-compliant sensor data for

a honeypot without relying on computationally expensive engineering simulations that are hard to deploy?

To address this challenge, we propose the *Adaptive Shadow Digital Twin (ASDT)*. This system employs a hybrid architecture that fuses first-principle physics modeling with data-driven residual learning. Specifically, we use a lifted Koopman operator framework to capture non-linear dynamics in a linear-evolved space, combined with a lightweight Long Short-Term Memory (LSTM) network to correct residual modeling errors. This allows the honeypot to generate sensor readings that statistically match the high-fidelity HAI dataset, deceiving attackers into believing they are manipulating a real physical process. The proposed ASDT framework not only secures critical infrastructure by deceiving sophisticated adversaries but also provides a low-cost, scalable alternative to expensive Hardware-in-the-Loop (HIL) setups. This enables small-to-medium industrial enterprises to deploy high-fidelity deception without the need for redundant physical assets.

The remainder of this paper is organized as follows. Section II reviews the related works and identifies the gap in current deception technologies. Section III mathematically formulates the semantic gap and the distinguishability problem. Section IV details the proposed ASDT architecture. Section V describes the experimental setup, Section VI presents the results, and Section VIII concludes the paper.

II. RELATED WORKS

This section reviews the evolution of deception technology in industrial environments. We categorize existing literature into three main areas: standard high-interaction honeypots, physics-based fingerprinting attacks, and the emergence of DTs for security. Finally, we highlight the limitations of current approaches and define the specific research gap that this paper addresses.

A. State-of-the-art ICS Honeypots

Conpot has been the most widely used ICS honeypot, emulating protocols such as Modbus and S7comm [6]. However, its detection is relatively easy because of static responses that do not reflect real system behavior. To address this, recent work has introduced High-Interaction Honeypots (HIH). For instance, HoneyVP [7] connects virtual decoys to real devices to generate more realistic traffic patterns. More recently, SGPot [8] used Reinforcement Learning (RL) to model smart grid substation behavior. Similarly, Norton et al. developed

a container-based honeypot that replicates real PLC network response delays to evade modern scanners [9].

Despite these advances, current tools mainly focus on protocol-level imitation rather than modeling physical industrial processes such as temperature or mechanical speed. SGPot itself notes that the lack of physical process simulation is still a major limitation [8], leaving systems vulnerable to physics-aware attacks. More recently, Donadel et al. proposed SimProcess [5], a high-fidelity simulator using Modelica-based physical modeling. Although it provides strong realism, it requires high computational cost (over 10 ms inference) and expert knowledge to build models. ASDT mitigates this limitation using hybrid data-driven residual learning techniques.

B. Physics-Based Fingerprinting Attacks

Sophisticated attackers now go beyond simple network scanning and target the physical layer of ICS systems to detect deceptive environments. This is often called “physics-based fingerprinting,” since real industrial devices such as pumps or turbines have unique physical behaviors that are difficult to imitate in software. For example, Gu et al. [10] showed that actuator response time can act as a fingerprint. By measuring how long a valve needs to open or close, attackers can differentiate real hardware from simulated devices. Similarly, Ahmed et al. [11] proposed using sensor noise as a fingerprint. Real sensors always generate characteristic noise patterns due to hardware imperfections and environmental conditions, while typical honeypots often output overly clean data or artificial random noise that fails to match real physical processes [11].

In addition, attackers can perform “active challenge” attacks by sending specific commands and observing system residuals. Ahmed and Mathur [12] showed that deviations in noise patterns can reveal whether a sensor is real or simulated. If the observed residuals (r_k) do not follow expected physical laws, attackers can quickly detect the presence of a honeypot.

C. Process-Aware Deception and DTs

To overcome the limitations of static honeypots, researchers have adopted DT technology [13]. A DT is a virtual replica of a physical system that imitates its real behavior, including both network communication and physical process dynamics, such as fluid level changes in a tank. Choi et al. [14] showed that DTs can be built using industrial equipment to accurately model PLC and HMI interactions. Their results indicated that reproducing realistic physical scenarios improves attack analysis. Based on this idea, Process-Aware Deception emerged, aiming to solve physical system equations (e.g., $\mathbf{A}x_k + \mathbf{B}u_k$) in real time to generate believable sensor outputs.

Recently, Cichocki proposed AI-driven DTs for maritime cybersecurity [15], arguing that AI-based deception enables adaptive defenses against sophisticated attackers. This trend moves from simple prerecorded honeypots toward complex mathematical and data-driven simulation environments that are harder to fingerprint.

D. Research Gap and Contribution

Despite recent advances, achieving high-fidelity deception remains an open challenge. Existing methods are mainly divided into physics-based models, which are accurate but

computationally expensive [5], and data-driven models, which can behave like black boxes and sometimes violate physical laws, making them detectable by advanced attackers [8].

To the best of our knowledge, no prior work has applied a hybrid approach combining first-principle physics with data-driven residual learning specifically for real-time ICS deception. This paper addresses this gap by proposing ASDT, which uses simplified physics models for stability and neural correction for nonlinear behavior approximation, improving realism against fingerprinting attacks.

III. PROBLEM STATEMENT

ICS honeypots must closely resemble real systems. Although tools such as Conpot mimic network protocols (e.g., Modbus, DNP3), they cannot accurately reproduce physical process dynamics, creating a detectable “process fidelity gap”. Attackers can exploit this gap using physics-based fingerprinting.

A. Koopman-Based Lifting of Nonlinear Dynamics

Traditional linear models cannot capture complex nonlinear behaviors in systems like gas pipelines. To address this, we use Koopman Operator theory, which represents nonlinear dynamics as linear evolution in a higher-dimensional function space. Let $\psi(x_k)$ denote nonlinear observable functions. The dynamics can be written as:

$$z_{k+1} = \mathbf{K}z_k + \mathbf{B}_z u_k + \omega_k, \quad z_k = \psi(x_k) \quad (1)$$

where $\mathbf{K}$ is the Koopman matrix, $z_k \in \mathbb{R}^K$ ($K \gg n$) is the lifted state, and ω_k represents the unmodeled truncation error. This framework captures nonlinear transients that conventional state-space models miss.

In contrast, existing honeypots usually lack a proper evolution model $\mathbf{A}$. When an attacker sends a control command u_k , the honeypot response y_k^{hp} is often generated using static or random mappings:

$$y_k^{hp} = \mathcal{F}(u_k), \quad \frac{\partial y_k^{hp}}{\partial t} \approx \frac{\partial y_k^{real}}{\partial t} \quad (2)$$

Here, y_k^{hp} is the synthetic sensor output and $\mathcal{F}$ is a heuristic mapping such as lookup-table generation. This causes temporal inconsistency between honeypot responses and real physical process behavior.

B. The Physics-Based Fingerprinting Attack

Sophisticated malware, aware of the physical constraints found in the HAI dataset (e.g., rotor inertia or thermal capacitance), can execute a “Challenge-Response” test. The adversary injects a specific input sequence $U = \{u_k, \dots, u_{k+N}\}$ and monitors the residual r_k between the observed response and the expected physical behavior derived from physics laws:

$$r_k = \|y_k - [\mathbf{C}_z (\mathbf{K}z_{k-1} + \mathbf{B}_z u_{k-1})]\|_2 \quad (3)$$

where $\|\cdot\|_2$ denotes the Euclidean norm, $z_k = \psi(x_k)$ is the lifted state, and $\mathbf{K}, \mathbf{B}_z, \mathbf{C}_z$ are the Koopman evolution matrices. A standard honeypot exhibits $r_k \gg \epsilon$ (threshold ϵ), revealing deception.

In a standard honeypot, r_k diverges significantly ($r_k \gg \epsilon$), revealing the deceptive nature of the target. This paper

addresses the challenge of minimizing r_k in real-time by integrating a shadow DT that mirrors the non-linear dynamics observed in the HAI testbed, thereby rendering the honeypot mathematically indistinguishable from the physical asset.

C. Threat Model and Assumptions

We assume a **sophisticated adversary** with the following capabilities:

- **Network Access:** Full Modbus/DNP3 protocol knowledge and ability to inject arbitrary commands.
- **Physics Knowledge:** Understanding of industrial process dynamics (state-space models, conservation laws).
- **Black-box Testing:** Ability to probe honeypot with 10,000+ queries over hours/days.
- **Statistical Analysis:** Tools for time-series analysis (FFT, autocorrelation, residual testing).

We do **not** assume:

- Compromise of the host operating system or Docker container.
- Physical access to industrial equipment.

Note on Advanced Persistent Threats: While our primary threat model assumes black-box probing, Section VII also evaluates a worst-case white-box scenario (where the attacker extracts matrices $\mathbf{K}, \mathbf{B}_z, \mathbf{C}_z$) to formally demonstrate the theoretical limits of ASDT's robustness.

This threat model aligns with realistic APT reconnaissance phases where attackers fingerprint systems before launching targeted exploits [10].

IV. PROPOSED METHODOLOGY: ASDT

To bridge the semantic gap identified in Section III, we propose the ASDT. Unlike static simulators, ASDT employs a hybrid architecture that fuses first-principle physics modeling with data-driven residual learning. This approach ensures that the honeypot's response dynamics ($\hat{y}_k$) statistically converge to the ground truth observed in the HAI dataset, even under unknown attack vectors.

A. Architecture Overview

The proposed framework consists of three coupled modules:

- 1) **Traffic Forking Engine:** Uses iptables to intercept Modbus/DNP3 packets and forward them to isolated Docker container. Pymodbus 3.5.2 parses function codes before state estimation.
- 2) **The Physics-Informed Core:** Calculates the nominal state evolution based on linearized system matrices derived from the HAI testbed topology.
- 3) **The Neural Residual Corrector:** A lightweight LSTM network that predicts the non-linear deviation (residuals) that the linear physics model fails to capture, ensuring high-fidelity mimicry of sensor noise and complex fluid dynamics.

Isolation and Security: ASDT runs in a hardened Docker container with: (1) read-only root filesystem, (2) dropped capabilities (CAP_NET_RAW retained for raw socket), (3) AppArmor profile restricting syscalls, (4) resource limits (512 MB RAM, 2 CPU cores). Network isolation via dedicated

VLAN prevents lateral movement if container is compromised.

Figure 1 illustrates the complete ASDT architecture with data flow between components.




Figure 1. High-level architecture of the Koopman-based ASDT. The system lifts the physical states into a higher-dimensional functional space, applies PINN-constrained LSTM residual corrections, and enforces BIBO stability through a Lyapunov projection layer before synthesizing the deceptive sensor responses.

B. Physics-Informed Hybrid State Evolution

The ASDT state update is a constrained optimization problem. We define the state transition in the lifted Koopman space:

$$\hat{z}_{k+1} = \mathbf{K}\hat{z}_k + \mathbf{B}_z u_k^{att} + \mathcal{N}_\theta(z_k, u_k^{att}) \quad (4)$$

To ensure physical consistency, the neural corrector $\mathcal{N}_\theta$ is trained using a multi-objective physics-informed loss function:

$$\mathcal{L} = \mathcal{L}_{MSE} + \lambda_{phys} \|\nabla \cdot \mathcal{F}(\mathbf{C}_z \hat{z}_{k+1})\|_2^2 + \lambda_{reg} \|\theta\|_2 \quad (5)$$

where $\mathcal{F}(\cdot)$ represents differential operators (e.g., mass-balance) applied to the reconstructed physical state. While previous works successfully utilize physical conservation laws and mass-balance residuals to detect anomalies in critical infrastructures [16], [17], this work is the first to adapt this principle into a generative constraint for real-time deception.

C. Stability Guarantees via Dissipative Projection

To prevent LSTM-induced state drift or non-physical divergence, we implement a Lyapunov-based projection layer. We define a quadratic energy function $V(z) = z^T \mathbf{P} z$. The state update is projected onto the invariant set $\Omega = \{z : V(z) \leq V_{max}\}$:

$$\hat{z}_{k+1} = \text{proj}_\Omega (\mathbf{K}\hat{z}_k + \mathbf{B}_z u_k^{att} + \mathcal{N}_\theta(\dots)) \quad (6)$$

This guarantees that even under aggressive adversarial probing, the honeypot states remain bounded within the operational envelope of a real physical asset.

D. Response Synthesis and Latency Injection

To prevent timing-based fingerprinting, the generated sensor output $\hat{y}_k$ must include realistic measurement noise and processing delays. The synthesized sensor output (Eq. 7) includes realistic noise: The synthesized sensor output $\hat{y}_k$ is mapped back from the lifted space using the output matrix $\mathbf{C}_z$:

$$\hat{y}_k = \mathbf{C}_z \mathbf{z}_{k+1} + \eta_k, \quad \eta_k \sim \mathcal{N}(0, \Sigma_{HAI}) \quad (7)$$

where $\Sigma_{HAI} \in \mathbb{R}^{p \times p}$ is the noise covariance extracted from 100 hours of stable HAI operation. This ensures that the generated values contain the device-specific "analog jitter" that attackers use for sensor fingerprinting.

To prevent timing-based fingerprinting, we enforce deterministic cycle consistency via a PREEMPT_RT kernel with CPU affinity. The response latency follows:

$$\Delta t = \max(T_{scan}, T_{proc}) + \xi_k, \quad \xi_k \sim \text{Gamma}(\alpha, \beta) \quad (8)$$

where $T_{scan} = 100$ ms (HAI P1 nominal, hardware-locked via OpenPLC's internal timer), T_{proc} is LSTM inference time, and ξ_k models the non-deterministic TCP/IP stack and network interface jitter following a Gamma distribution with shape $\alpha = 16.2$ and rate $\beta = 34.5$. These parameters were derived via Maximum Likelihood Estimation (MLE) fitted to 10,000 real PLC response traces from the HAI testbed to ensure statistical indistinguishability. The max operator ensures a deterministic physical processing lower-bound consistent with IEC 61131-3 standards on the PREEMPT_RT kernel, while ξ_k mimics the realistic network delay distribution that attackers observe, preventing rigid timing-based fingerprinting.

E. Execution Algorithm

The operational logic of the ASDT is formalized in Algorithm 1.

Algorithm 1 Execution Logic of the Koopman-ASDT

Require: Koopman Matrices $\mathbf{K}, \mathbf{B}_z, \mathbf{C}_z$, Lifting Function $\psi(\cdot)$, Residual LSTM $\mathcal{N}_\theta$, Latency Profile $\Gamma(\alpha, \beta)$
Input: Incoming Attacker Packet P_{in}
Output: Synthesized Response Packet P_{out}

```

1: Initialization:  $z_0 \leftarrow \psi(x_{steady})$   $\triangleright$  Lift initial state to Koopman space
2:  $k \leftarrow 0$ 
3: while Session is Active do
4:  $\triangleright$  Step 1: Context-Aware Parsing
5:  $u_k^{att} \leftarrow \text{ParsePayload}(P_{in})$ 
6:  $\triangleright$  Step 2: Hybrid Lifted State Estimation
7:  $z_{linear} \leftarrow \mathbf{K}z_k + \mathbf{B}_z u_k^{att}$   $\triangleright$  Linear evolution in lifted space
8:  $\delta_{residual} \leftarrow \mathcal{N}_\theta(z_k, u_k^{att})$   $\triangleright$  PINN-constrained correction
9:  $z_{k+1} \leftarrow \text{proj}_\Omega(z_{linear} + \delta_{residual})$   $\triangleright$  Lyapunov Projection (Eq. 6)
10:  $\triangleright$  Step 3: Realistic Sensor Synthesis
11:  $\hat{y}_{k+1} \leftarrow \mathbf{C}_z z_{k+1} + \eta_k, \quad \eta_k \sim \mathcal{N}(0, \Sigma_{HAI})$ 
12:  $\triangleright$  Step 4: Timing Masking
13:  $\Delta t \leftarrow \max(T_{scan}, T_{proc}) + \xi_k, \quad \xi_k \sim \Gamma(\alpha, \beta)$ 
14: clock_nanosleep( $\Delta t$ )
15: Send  $P_{out} \leftarrow \text{ConstructModbus}(\hat{y}_{k+1})$ 
16:  $k \leftarrow k + 1$ 
17: end while
    
```

V. EXPERIMENTAL SETUP

A. Infrastructure and Dataset

Training Workstation: Intel i9-14900K and NVIDIA RTX 4070 were used strictly for offline model training. **Deployment Target:** To validate real-world operational feasibility, the inference engine was deployed on a Raspberry Pi 4 (Quad-core Cortex-A72, 4GB RAM) representing a typical

edge gateway. Software: Ubuntu 22.04 with PREEMPT_RT, PyTorch 2.1.0, OpenPLC v3, Factory I/O v2.5.3.

We use the HAI dataset [18] P1 gas pipeline (1,095 hours), split chronologically: 60% train, 20% validation, 20% test. Preprocessing: outlier removal, normalization, differencing (stationarity verified via ADF test), 60-sample windows (50% overlap).

B. Model Configuration

The ASDT framework adopts a **grey-box modeling** architecture, which integrates the structural stability of state-space representations with the flexible non-linear mapping of deep learning.

1) *Koopman Spectral Identification:* To identify the operator $\mathbf{K}$, we employ the Extended Dynamic Mode Decomposition (EDMD) algorithm on the HAI P1 dataset. We selected a dictionary of $K = 48$ nonlinear lifting functions, including thin-plate splines and trigonometric observables, to map the original 12-dimensional state into a higher-dimensional Koopman space. The resulting matrix $\mathbf{K}$ captures 92.4% of the spectral energy of the gas pipeline's pressure transients, providing a robust linear backbone for the neural residual corrector.

2) *LSTM Residual Corrector:* A neural corrector $\mathcal{N}_\theta$ is utilized to capture complex non-linearities such as valve hysteresis and thermal lag.

- **Input Handling:** To maintain temporal coherence, the LSTM processes a sliding window of $L = 60$ samples ($X_{k-L:k}, U_{k-L:k}$) rather than isolated data points.
- **Architecture:** The network consists of two LSTM layers (128 and 64 hidden units). A final **linear projection layer** is employed to map the hidden state output back to the 12-dimensional state residual space $\delta_{residual}$.
- **Activation and Stability:** The output layer utilizes a **Tanh activation** to bound the maximum residual correction. This ensures that the hybrid state update in the lifted Koopman space (Eq. 4) remains BIBO stable, with the Lyapunov projection (Eq. 6) guaranteeing bounded energy evolution.

3) *Adversarial Hardening and Training:* To defend against Model Extraction, we employ adversarial training. The LSTM is trained on a combination of HAI datasets and synthetic probing sequences generated by an auxiliary GAN. This ensures the model is robust not only to normal process noise but also to the "Challenge-Response" patterns used by sophisticated attackers for fingerprinting. The multi-objective loss (Eq. 5) is optimized using Adam with a learning rate of 1×10^{-3} .

Learning rate, batch size, and hidden units were tuned via grid search on validation set. Tested ranges: LR $\in \{1e-4, 5e-4, 1e-3, 5e-3\}$, batch size $\in \{64, 128, 256, 512\}$, hidden units $\in \{32/16, 64/32, 128/64, 256/128\}$. Optimal configuration (Table I) minimized validation loss while maintaining inference latency < 2.5 ms.

The LSTM residual corrector is trained using the physics-informed loss function defined in Eq. 5, which enforces adherence to mass-balance and energy conservation constraints. Training converged in 47 minutes on RTX 4070 at epoch 112 with validation loss 0.0023 (training loss 0.0019). Validation

Table I
LSTM NETWORK HYPERPARAMETERS

Hyperparameter	Value
Input Features	20 (12 states + 8 controls)
Hidden Units (Layer 1)	128
Hidden Units (Layer 2)	64
Output Dimension	12 (state residuals)
Dropout Rate	0.2
Activation Function	Tanh
Optimizer	Adam ($\beta_1 = 0.9, \beta_2 = 0.999$)
Learning Rate	1×10^{-3} (with decay)
Batch Size	256
Training Epochs	150 (early stopping at 112)
Loss Function	PINN-based Loss (Eq. 5)

R^2 reached 0.938 at epoch 112, with no improvement for 15 consecutive epochs, triggering early stopping. Training breakdown: data loading (3 min), forward-backward passes (41 min), validation (3 min). Total energy consumption: 0.18 kWh (RTX 4070 TDP 200W). Model size is 1.8 MB (INT8 quantized: 487 KB), enabling deployment on ARM-based industrial gateways (tested on Raspberry Pi 4 with 3.2 ms inference).

Baselines: We compare against four systems: (B1) Linear Physics Only (state-space without residual correction), (B2) Pure LSTM (2-layer, 128/64 hidden units, no physics constraints). **Note:** B2 uses the exact same architectural capacity as ASDT to ensure a strictly fair comparison. This proves that without Koopman lifting and PINN constraints, the data-driven model inherently violates physical laws. (B3) Conpot v0.6.0 (static lookup tables with uniform random noise $\mathcal{U}(-0.05, 0.05)$), and (B4) Random Noise Injection (Gaussian $\mathcal{N}(\mu_{HAI}, \sigma_{HAI})$ without temporal correlation). Note: HoneyVP [7] and SGPot [8] were excluded as they require proprietary hardware testbeds and lack publicly available implementations for fair comparison.

B2 Details: Same inputs (12 states + 8 controls) as ASDT but trains on y_k without physics. Uses 2 LSTM layers (128/64), Adam, Huber loss. Converged at epoch 98 (val loss 0.0041 vs. 0.0023 for ASDT).

Fidelity Metrics: We quantify reconstruction accuracy using standard error-based metrics including Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), and coefficient of determination (R^2). These metrics are used to measure the difference between real sensor values and ASDT predictions, while Peak Signal-to-Noise Ratio (PSNR) is used to evaluate signal quality.

Statistical Divergence: To measure distributional similarity, we employ the Kullback-Leibler divergence:

$$D_{KL}(P||Q) = \sum_i P(i) \log \frac{P(i)}{Q(i)} \quad (9)$$

where P is the empirical distribution of real HAI data and Q is the distribution of ASDT-generated sensor values. We also compute Jensen-Shannon divergence and Wasserstein distance for robust distributional comparison.

Indistinguishability: A Random Forest discriminator is trained to classify real versus synthetic sensor data. Detection accuracy near 50% and ROC-AUC ≈ 0.5 indicate statistical indistinguishability, demonstrating that the honeypot successfully evades ML-based fingerprinting attacks.

Real-Time Performance: We measure inference latency (packet-to-response time), throughput (packets/sec), memory footprint, and CPU/GPU utilization to verify deployability on commodity hardware.

Physical Robustness: We designed six attack scenarios (Table II) to evaluate ASDT’s resilience against physics-based fingerprinting. Table III presents detection outcomes.

Table II
ATTACK SCENARIOS FOR ROBUSTNESS EVALUATION

Scenario	Description	Duration	Detection Goal
A1	Reconnaissance scan with Nmap and Modbus function code enumeration	5 min	Protocol fingerprint
A2	Rapid command injection (valve open/close at 10 Hz)	30 sec	Transient response
A3	Stealthy setpoint manipulation with gradual drift over time	60 min	Long-term physics behavior
A4	Multi-variate correlation test for pump-pressure coupling	10 min	Cross-sensor dynamics
A5	Response time fingerprinting using RTT analysis	2 min	Network latency signature
A6	Noise spectral analysis using FFT on sensor signals	15 min	Sensor noise profile detection

Table III
ATTACK SCENARIO RESULTS (DETECTION = HONEYPOT IDENTIFIED)

Scenario	Conpot	Pure LSTM	ASDT
A1: Protocol Scan	✓	✓	—
A2: Transient Test	✓	✓	—
A3: Long-term Drift	✓	—	—
A4: Correlation Test	✓	✓	—
A5: RTT Analysis	✓	—	—
A6: Noise Spectrum	✓	✓	—

Detailed Analysis: A1: Nmap identified Conpot via missing Modbus exception codes. ASDT mimics Schneider M221 PLC responses exactly. **A2:** 10 Hz valve toggling revealed Conpot’s zero settling time. ASDT replicates 340 ms electro-hydraulic actuator delay (Fig. 2).




Figure 2. Transient response analysis during a valve step-change. ASDT replicates the physical inertia and settling time accurately.

A3: 60-minute gradual pressure increase exposed Pure LSTM’s mass-balance violation (divergence after 42 min). ASDT maintains $r_{mass} < 2.1$ throughout. **A4:** Pump-pressure correlation: Conpot shows zero cross-correlation. ASDT preserves Pearson $\rho = 0.87$ (vs. 0.89 in real data). **A5:** RTT fingerprinting: Conpot shows constant 12 ms response. ASDT’s Gamma jitter prevents clustering (Kolmogorov-Smirnov test: $p = 0.53$ vs. real PLC). **A6:** FFT analysis: Random Noise

(B4) shows flat spectrum. ASDT replicates $1/f$ pink noise from sensor ADC quantization (Fig. 3).




Figure 3. Power Spectral Density of sensor noise. ASDT captures the high-frequency characteristics ignored by B4.

Detection Methodology: For each attack scenario, we applied three independent detection methods: (1) Protocol fingerprinting (checking Modbus exception codes, timing signatures), (2) Physics residual test (Eq. 3 with threshold $\epsilon = 0.1$), (3) Statistical test (Kolmogorov-Smirnov on sensor distributions, $p < 0.05$ indicates detection). A honeypot is marked "Detected" if any method successfully identifies it as non-authentic.

C. Statistical Validation and Reproducibility

To ensure statistical significance, we apply: (1) Diebold-Mariano test for predictive accuracy comparison (ASDT vs. B2: DM statistic = -12.47, $p < 0.001$, confirming ASDT superiority), (2) Wilcoxon signed-rank test for error distributions ($W = 1.24 \times 10^6$, $p < 0.001$, rejecting null hypothesis of equal medians), and (3) bootstrap confidence intervals (10,000 stratified resamples) for 95% CI on all metrics.

VI. RESULTS AND EVALUATION

This section presents a comprehensive quantitative and qualitative analysis of the ASDT. We evaluate the system across four dimensions: fidelity, indistinguishability, physical robustness, and real-time deployability.

A. Overall Reconstruction Fidelity

Table IV presents the primary reconstruction metrics on the HAI test set. By utilizing the Koopman-based lifting functions (Eq. 1), ASDT captures the high-rank nonlinearities of the gas pipeline that are lost in standard Jacobian linearization (B1). The ASDT achieves a coefficient of determination (R^2) of 0.943 and a PSNR of 28.45 dB, significantly outperforming protocol-only honeypots like Conpot (B3) which lack temporal process dynamics.

The low KL divergence confirms that the probability distribution of ASDT sensor readings is nearly identical to the ground truth, as visualized in the KDE plot (Fig. 4).

B. Indistinguishability: The Adversarial Turing Test

To evaluate deception efficacy, we employ two complementary tests: (1) a Random Forest discriminator for statistical pattern matching, and (2) a physics-based residual analysis using Kalman filtering. For the latter, we compute the innovation sequence $\nu_k = y_k - \mathbf{C}_z(\mathbf{K}\hat{\mathbf{z}}_{k-1} + \mathbf{B}_zu_{k-1})$ and apply a CUSUM detector. This test is critical for detecting False Data




Figure 4. Kernel Density Estimation (KDE) of sensor values showing the statistical overlap between ASDT and real data.

Injection (FDI) attacks where adversaries inject fabricated sensor values—if ν_k exhibits non-white autocorrelation, it signals non-physical behavior. ASDT maintains ν_k whiteness (Ljung-Box p-value = 0.68), matching real data ($p = 0.71$), whereas Conpot exhibits autocorrelation ($p < 0.001$).

The Random Forest classifier (100 trees, max depth = 10) was trained on 20,000 samples (10K real HAI, 10K ASDT synthetic) with an 80/20 train-test split. Features include time- and frequency-domain statistics (mean, std, skewness, kurtosis, FFT coefficients, PSD) and temporal correlations (autocorrelation lags 1–5). The near-random accuracy (53.8% in Table V) confirms ASDT's deception efficacy, even against feature-engineered Random Forest sniffers (FFT, autocorrelation), as shown in Fig. 5.




Figure 5. ROC curves for discriminator attack. ASDT hugs the diagonal, representing ideal indistinguishability.

C. Physics Constraint and Transient Validation

A critical metric for honeypot indistinguishability is the residual r_{mass} , representing the violation of the mass-balance invariant. As shown in Table VI and visualized in Fig. 6, the unconstrained LSTM (B2) exhibits significant non-physical drift during transients, with peak violations reaching 47.82. By integrating the physics-informed loss (Eq. 5), ASDT reduces these violations by over an order of magnitude. This ensures that even under high-frequency actuation (Scenario A2), the generated sensor data resides on the invariant manifold of physically feasible states. This behavior is a direct consequence of the Lyapunov projection (Eq. 6), which constrains the state evolution within the dissipative energy bounds of the original gas pipeline system.

Table IV
COMPREHENSIVE RECONSTRUCTION FIDELITY COMPARISON (ASDT VS. BASELINES). ARROWS ($\uparrow, \downarrow$) INDICATE BETTER PERFORMANCE DIRECTION.

Model	RMSE $\downarrow$ (normalized)	MAE $\downarrow$ (normalized)	$R^2\uparrow$	PSNR $\uparrow$ (dB)	KL Div. $\downarrow$ (nats)	JS Div. $\downarrow$ (nats)	Wasserstein $\downarrow$ ($\times 10^{-3}$)
B1: Linear Physics (Jacobian)	0.0892	0.0710	0.651	21.34	0.4217	0.2108	24.53
B2: Pure LSTM (Unconstrained)	0.0645	0.0483	0.824	24.81	0.1842	0.0921	11.27
B3: Conpot (Protocol-Only)	0.1523	0.1204	0.312	17.92	0.8934	0.4467	48.91
B4: Random Noise Injection	0.1047	0.0821	0.534	20.18	0.5612	0.2806	31.45
ASDT (Koopman + PINN)	0.0412$\pm$0.0018	0.0295$\pm$0.0012	0.943$\pm$0.007	28.45$\pm$0.34	0.0341$\pm$0.0023	0.0171$\pm$0.0015	4.82$\pm$0.41
<i>Improvement vs. Best Baseline</i>	<i>36.1%</i>	<i>38.9%</i>	<i>14.4%</i>	<i>14.7%</i>	<i>81.5%</i>	<i>81.4%</i>	<i>57.2%</i>

Note on Baseline Performance: Conpot's low R^2 (0.312) confirms that protocol honeypots cannot survive physics-based fingerprinting. B1's failure in transient regions justifies the need for Koopman lifting, while ASDT's low Wasserstein distance proves its statistical indistinguishability from the real HAI testbed.

Table V
ADVERSARIAL DISCRIMINATOR PERFORMANCE (LOWER IS BETTER). RF ACCURACY NEAR 50% INDICATES IDEAL INDISTINGUISHABILITY.

Honeypot	RF Acc. (%)	ROC-AUC	CUSUM p-val $\uparrow$	ACF Lag-1 $\downarrow$
B1: Linear Physics	94.2%	0.987	0.12	0.43
B2: Pure LSTM	76.5%	0.842	0.03	0.29
B3: Conpot	98.7%	0.999	< 0.001	0.87
ASDT	53.8% $\pm$ 2.1%	0.532	0.68	0.09
<i>HAI Real</i>	—	—	0.71	0.08

Table VII
INFERENCE LATENCY STATISTICS (MS)

Hardware	Mean	Std Dev	Median	95th %	99th %
i9-14900K (Workstation)	4.23	0.87	4.18	5.67	7.12
RTX 4070 (Training)	1.87	0.34	1.82	2.34	2.89
Raspberry Pi 4 (Edge)	3.21	0.45	3.15	3.89	4.12

Table VIII
SYSTEM RESOURCE UTILIZATION

Metric	CPU Mode	GPU Mode	Limit
Throughput (pkt/s)	237	534	—
Memory (RSS)	142 MB	387 MB	512 MB
CPU Usage	31%	8%	50%
GPU Usage	—	23%	80%




Figure 6. (Top) Time-series residual r_k from Eq. 3 during 1000-second test sequence with step input at $t=500$ s. ASDT maintains $r_k < 0.05$ (gray zone), while Pure LSTM diverges. (Bottom) Mass conservation violation $\|\nabla \cdot \mathbf{v}\| < \epsilon_{mass} = 5.67$ (HAI threshold). Pure LSTM exhibits $10\times$ higher violations (red spikes at transients), exposing physics-based fingerprinting vulnerability.

D. Real-Time Performance Analysis

Inference latency statistics (Table VII) confirm that ASDT send deceptive responses without detectable network jitter.

As detailed in Table VIII, ASDT sustains 534 packets/second (sufficient for typical SCADA polling at 1-10 Hz per device), with memory footprint under 512 MB Docker limit.

Table VI
PHYSICS CONSTRAINT VIOLATION (r_{mass}) ANALYSIS

Model	Mean Violation	Max Peak (Transients)
B2: Pure LSTM (Unconstrained)	12.34	47.82
ASDT (Without PINN Loss)	4.52	15.61
ASDT (Full Koopman+PINN)	1.18	4.21
<i>HAI Ground Truth</i>	<i>1.12</i>	<i>3.98</i>

E. Ablation Study

To validate design choices, we conducted ablation experiments on LSTM architecture:

Layer Depth: Table IX shows 2-layer LSTM achieves optimal trade-off. Single-layer underfits ($R^2 = 0.891$), while 3-layer overfits (validation loss increases after epoch 78).

Table IX
ABLATION STUDY: LSTM LAYER DEPTH

Configuration	$R^2\uparrow$	RMSE $\downarrow$	Latency (ms)
1-Layer (128 units)	0.891	0.0567	1.34
2-Layer (128/64)	0.943	0.0412	1.87
3-Layer (128/64/32)	0.938	0.0429	2.93

Hidden Units: We tested configurations from 32 to 256 units. 128/64 balances expressiveness (captures valve hysteresis nonlinearity) and efficiency (model size 1.8 MB vs. 7.2 MB for 256/128).

Activation Functions: Tanh outperforms ReLU ($R^2 = 0.921$) and ELU ($R^2 = 0.929$) due to bounded output preventing gradient explosion in recurrent connections.

VII. DISCUSSION

Koopman theory and Physics-Informed Learning address ICS decoy issues such as transient mismatch and physical inconsistency. While high-fidelity simulators (e.g., SimProcess) are realistic, they are often too slow for real-time PLC execution. ASDT mitigates this by lifting nonlinear dynamics into a Koopman linear space, enabling inference times under 4 ms. Adversarial training further improves robustness, where the neural corrector $\mathcal{N}_\theta$ is trained using GAN-style probing data to capture sensor noise statistics (Σ_{HAI}). This yields 53.8% accuracy in adversarial Turing tests, close to random guessing.

The discriminator results (Table V) confirm this indistinguishability. AI-driven DTs are known to be vulnerable to adversarial parameter manipulation [19]. White-box attackers knowing matrices $\mathbf{K}$, $\mathbf{B}_z$, $\mathbf{C}_z$ could design stronger tests. To mitigate this, we applied two defenses: (1) Matrix perturbation using Gaussian noise $\mathcal{N}(0, 0.02\mathbf{I})$, reducing attack detection from 87% to 61% while keeping $R^2 > 0.91$; (2) Ensemble switching between 3 ASDT models every 10 minutes, increasing model extraction cost beyond 100 hours. Model extraction attacks were also simulated using 10,000 query inputs. With PATE-style privacy noise ($\epsilon = 0.5$), extraction accuracy dropped to 34% from 89%, while fidelity remained high ($R^2 = 0.927$). Limiting queries to 50 per minute further increased attack cost to 167+ hours.

ASDT also supports real-time operation with <3 ms latency and a compact 1.8 MB model size, allowing deployment on edge industrial gateways.

Limitations: Training data bias is a main issue. The model was trained mainly on HAI P1 gas pipeline data, which mostly represents low turbulence flow. Systems with turbulent or chemical dynamics may need nonlinear models. Cross-domain tests on HAI P2 (water treatment) gave $R^2 = 0.782$ without retraining (Koopman matrices require process-specific recalibration), improving to 0.894 after 50 epochs of fine-tuning (LSTM architecture and PINN loss structure transfer directly). Out-of-distribution attacks increase RMSE up to 0.102.

Future Work: Future research will explore online learning with anomaly-triggered retraining, multi-fidelity modeling combining fast linear and slow high-fidelity simulations, formal verification using Signal Temporal Logic, and federated threat intelligence sharing across industrial networks.

VIII. CONCLUSION

This paper introduced ASDT, a hybrid honeypot architecture that bridges the ICS semantic gap through Koopman lifting and PINN-constrained residuals. Unlike protocol-only honeypots (e.g., Conpot) or unconstrained ML models, ASDT provides a formal stability guarantee via Lyapunov projection and statistical indistinguishability ($\text{ROC-AUC} \approx 0.5$). Experimental validation on the HAI benchmark demonstrates that ASDT maintains physical consistency ($r_{mass} < 1.2$) even under aggressive adversarial challenges, with real-time performance on edge hardware. Future research will extend this framework to multi-phase fluid systems and explore federated threat intelligence for large-scale distributed ICS environments.

ACKNOWLEDGEMENT

This activity has been co-financed 85% by the European Union, the European Regional Development Fund and the Regional Government of Extremadura. Managing Authority: Ministry of Finance. Grant File Number: GR24170.

DATA AVAILABILITY

The HAI dataset is publicly available at <https://github.com/icsdataset/hai>. Our trained models, system matrices, and evaluation scripts are available at <https://github.com/homaei/ASDT-Honeypot-E4F2>. Due to security concerns, we do not

release complete Docker images or deployment configurations that could facilitate adversarial honeypot identification research.

REFERENCES

- [1] S. Rashid, A. Haq, S. Hasan, M. Furhad, M. Ahmed, and A. Ullah, "Faking smart industry: exploring cyber-threat landscape deploying cloud-based honeypot," *Wireless Networks*, vol. 30, pp. 4527–4541, 2024.
- [2] E. López-Morales, "Securing cyber-physical systems via advanced cyber threat intelligence methods," in *Proceedings of the 2024 ACM SIGSAC Conference on Computer and Communications Security (CCS '24)*, 2024, pp. 5119–5121.
- [3] L. Salazar, E. López-Morales, J. Lozano, C. Rubio-Medrano, and Á. Cárdenas, "Icsnet: A hybrid-interaction honeynet for industrial control systems," in *Proceedings of the 6th Workshop on CPS and IoT Security and Privacy (CPSIoTSec '24)*, 2024, pp. 68–79.
- [4] H. Zhu, M. Liu, B. Chen, X. Che, P. Cheng, and R. Deng, "Honeyjudge: A plc honeypot identification framework based on device memory testing," *IEEE Transactions on Information Forensics and Security*, vol. 19, pp. 6028–6043, 2024.
- [5] D. Donadel, G. Crestanello, G. Morandini, D. Antoniolli, M. Conti, and M. Merro, "Simprocess: High fidelity simulation of noisy ics physical processes," in *Proceedings of the 11th ACM Cyber-Physical System Security Workshop (CPSS '25)*, 2025, pp. 6–18.
- [6] S. Bistarelli, E. Bosimini, and F. Santini, "A medium-interaction emulation and monitoring system for operational technology," in *Proceedings of the 2021 ACM Workshop on Secure and Trustworthy Cyber-Physical Systems (SAT-CPS '21)*, 2021, pp. 59–68.
- [7] J. You, S. Lv, Y. Sun, H. Wen, and L. Sun, "Honeyvyp: A cost-effective hybrid honeypot architecture for industrial control systems," *IEEE Access*, vol. 9, pp. 123 456–123 467, 2021.
- [8] Y. Wang, G. Zong, and Q. Wei, "Sgpot: A reinforcement learning-based honeypot framework for smart grid," *Computer Science*, 2024, publisher: Editorial office of Computer Science.
- [9] G. Norton, J. Landsborough, E. Orozco, and J. Fields, "Containerized cozenage: Exploring the effectiveness of high interaction ics honeypot containers," in *Proceedings of the 58th Hawaii International Conference on System Sciences (HICSS 2025)*, 2025, pp. 1116–1125.
- [10] Q. Gu, D. Formby, S. Ji, H. Çam, and R. Beyah, "Fingerprinting for cyber-physical system security: Device physics matters too," *IEEE Security and Privacy*, vol. 16, pp. 49–59, 2018.
- [11] C. Ahmed, J. Zhou, and A. Mathur, "Noise matters: Using sensor and process noise fingerprint to detect stealthy cyber attacks and authenticate sensors in cps," in *Proceedings of the 34th Annual Computer Security Applications Conference (ACSAC '18)*, 2018, pp. 566–581.
- [12] C. Ahmed and A. Mathur, "Hardware identification via sensor fingerprinting in a cyber physical system," in *Proceedings of the 2017 IEEE International Conference on Software Quality, Reliability and Security Companion (QRS-C)*, 2017, pp. 517–524.
- [13] M. Homaei, O. Mogollón-Gutiérrez, J. C. Sancho, M. Avila, and A. Caro, "A review of digital twins and their application in cybersecurity based on artificial intelligence," *Artificial Intelligence Review*, vol. 57, no. 8, Jul. 2024.
- [14] T. Choi, G. Bai, R. Ko, N. Dong, W. Zhang, and S. Wang, "An analytics framework for heuristic inference attacks against industrial control systems," in *Proceedings of the 2020 IEEE International Conference on Trust, Privacy and Security in Intelligent Systems and Applications (TPS-ISA)*, 2020, pp. 256–265.
- [15] R. Cichocki, "Artificial intelligence in maritime cybersecurity: Dual-use applications for defense and offense in the age of digital seas," *Scientific Journal of Gdynia Maritime University*, 2025, in Press.
- [16] M. Homaei, M. Tarif, P. G. Rodríguez, A. Caro, and M. Ávila, "Causal digital twins for cyber-physical security in water systems: A framework for robust anomaly detection," *Mach. Learn. Appl.*, vol. 23, no. 100824, p. 100824, Mar. 2026.
- [17] M. Homaei, I. Khazrak, R. Molano, A. Caro, and M. Avila, "Graph attention networks with physical constraints for anomaly detection," Jan. 2026.
- [18] H.-K. Shin, W. Lee, J.-H. Yun, and H. Kim, "Hai 1.0: Hil-based augmented ics security dataset," in *13th USENIX Workshop on Cyber Security Experimentation and Test (CSET '20)*. USENIX Association, 2020.
- [19] M. Homaei, V. Gonzalez Morales, O. Mogollon-Gutierrez, and A. Caro, "The dark side of digital twins: Adversarial attacks on ai-driven water forecasting," 2025.

Sesión de pósters 5

Gestión segura y descentralizada de DID Documents on-chain en Ethereum

Miguel Gómez-Carpena
ioBuilders
Madrid, 28223, España
miguel.carpena@io.builders

Jorge Lanza
LPCM, Universidad de Cantabria
Santander, 39005, España
jorge.lanza@unican.es

Luis Sánchez
LPCM, Universidad de Cantabria
Santander, 39005, España
luis.sanchez@unican.es

Resumen—En el ámbito de la Identidad Auto-Soberana (SSI) y Blockchain, los Identificadores Descentralizados (DIDs) constituyen un componente fundamental. Los DID Documents contienen información sobre la identidad y capacidades de un DID, incluyendo claves públicas, Service Endpoints y métodos de autenticación. Este artículo presenta SSIOBC (Self-Sovereign Identity over Blockchain), un sistema de contratos inteligentes en Ethereum que gestiona DID Documents completamente on-chain mediante un enfoque innovador. A diferencia de las soluciones existentes que habilitan interacción off-chain o almacenan referencias a DID Documents en la blockchain, el sistema propuesto permite generar nuevos DIDs, editar sus DID Documents y mantenerlos íntegramente on-chain, conservando el acceso off-chain para flexibilidad. Además, soporta interacción desde dentro de la blockchain mediante otros contratos inteligentes, habilitando integraciones avanzadas y control de acceso descentralizado sin intermediarios. Esta versión amplía el sistema con tres contribuciones significativas: desactivación y reactivación W3C-compliant con dos modos de operación, una arquitectura dual que ofrece variantes Full W3C y Ethereum-Native con reducción del 13 % en bytecode, y una función de autorización cross-DID que habilita autenticación nativa desde cualquier contrato inteligente. La validación experimental con 317 pruebas, cobertura superior al 98 % y datos experimentales reales confirma la viabilidad práctica del sistema completamente descentralizado.

Index Terms—Identidad Auto-Soberana (SSI), Identificador Descentralizado (DID), DID Documents, Blockchain, Ethereum, Contratos Inteligentes

Tipo de contribución: *Póster*

I. INTRODUCCIÓN

La Identidad Auto-Soberana (SSI) es un modelo en el que cada persona u organización controla directamente sus credenciales digitales, sin depender de proveedores intermediarios [6], [7]. El mecanismo técnico que lo habilita son los Identificadores Descentralizados (DIDs), estandarizados por el W3C [5]: cada DID apunta a un DID Document que contiene las claves públicas, métodos de autenticación y puntos de servicio que permiten verificar al sujeto. Este modelo habilita casos de uso como la emisión y verificación de credenciales académicas sin acudir a la universidad emisora, o el acceso a servicios públicos digitales sin ceder datos personales a la administración. Sin embargo, análisis recientes evidencian que la mayoría de implementaciones blockchain de SSI presentan deficiencias significativas en autonomía del usuario y control directo sobre datos de identidad [8]. Los enfoques actuales de gestión de DIDs perpetúan los problemas de centralización al almacenar información mínima on-chain mientras requieren sistemas off-chain para funcionalidad completa, creando una

brecha entre el potencial teórico de SSI y las implementaciones prácticas.

Tres limitaciones críticas impiden la verdadera descentralización: las arquitecturas basadas en eventos como ERC-1056 [1] sacrifican resolución en tiempo real requiriendo reconstrucción off-chain [11]; los enfoques híbridos como LACChain [2] crean dependencias de confianza que contradicen la descentralización; y las implementaciones con mediación institucional como EBSI [3] comprometen la participación permissionless, mientras los costes de despliegue de ONCHAINID [4] resultan significativamente superiores a los de alternativas basadas en eventos, sin ofrecer soporte multi-método.

Esta investigación establece tres objetivos para abordar estas limitaciones. Primero, desarrollar autenticación blockchain-nativa eliminando dependencias externas (mediación API, reconstrucción off-chain, aprobación institucional) preservando propiedades trustless. Segundo, diseñar una arquitectura de almacenamiento eficiente soportando múltiples métodos DID dentro de un framework de contrato unificado y W3C-compliant, previniendo fragmentación del ecosistema. Tercero, demostrar viabilidad económica del almacenamiento DID completamente on-chain mediante validación experimental con costes competitivos.

Este artículo presenta SSIOBC (SSI over Blockchain), un sistema que ofrece gestión de DIDs completamente on-chain sin sacrificar descentralización, rendimiento o cumplimiento de estándares. SSIOBC introduce innovaciones clave: almacenamiento hash-based eficiente en gas manteniendo documentos completos on-chain; soporte multi-método nativo habilitando operaciones cross-namespace; y verificación integrada de firmas Ethereum eliminando dependencias criptográficas externas. Nuestro trabajo anterior [14] estableció el primer sistema de gestión de DIDs completamente on-chain con estas tres innovaciones arquitectónicas; este artículo lo amplía con tres contribuciones adicionales: (1) desactivación y reactivación W3C-compliant de DIDs con dos modos de operación (self y controller), (2) una arquitectura dual con variantes Full W3C y Ethereum-Native que reduce el bytecode un 13 %, y (3) una función pública de autorización cross-DID (*isAuthorized()*) invocable desde cualquier contrato inteligente. El código fuente está disponible públicamente en <https://github.com/MiguelLZPF/SSIOBC-did> y <https://github.com/MiguelLZPF/SSIOBC-did-examples>.

II. TRABAJO RELACIONADO Y ANÁLISIS DE BRECHAS

II-A. Análisis comparativo de enfoques actuales

Los sistemas actuales de identidad basados en blockchain implementan enfoques arquitectónicos fundamentalmente diferentes, cada uno creando compromisos que impiden una gestión de identidad verdaderamente descentralizada e interoperable [12]. La Tabla I compara cuatro sistemas representativos actualmente utilizados en la práctica.

ERC-1056 [1] alcanza alta eficiencia de gas evitando almacenamiento persistente, pero exige reconstrucción off-chain: los resolvers agregan eventos históricos a lo largo de miles de bloques, introduciendo latencia y requiriendo infraestructura especializada que contradice los principios de descentralización y dificulta la integración con contratos inteligentes [11]. **LACChain** [2] extiende el modelo de eventos con almacenamiento híbrido pero lo hace sobre un Hyperledger Besu permissionado, implementando un modelo que requiere aprobación institucional para participación en la red mediante acuerdos formales de adscripción, comprometiéndose la operación autónoma y los principios *permissionless* esenciales para sistemas de identidad descentralizada.

EBSI [3] impone mediación API obligatoria y consenso proof-of-authority restringido a estados miembros de la UE, donde la interacción con clientes Ethereum se restringe mediante pasarelas API, eliminando las propiedades *trustless* de blockchain a cambio de cumplimiento regulatorio. **ONCHAINID** [4] proporciona almacenamiento on-chain completo y compatibilidad cross-chain, pero depende de estándares pre-W3C (ERC-734/735) y de proxies actualizables (*beacon proxies*, *IdFactory*) que reintroducen riesgos de centralización y barreras de interoperabilidad con infraestructura DID contemporánea.

Tabla I
ANÁLISIS COMPARATIVO DE ENFOQUES ACTUALES.

Sistema	Arquitectura	Ubic. datos	W3C	Resol. t.r.	Efic. gas	Interop.
ERC-1056	Eventos	Solo eventos	Completo	No	Alta	Limitada
LACChain	Híbrida	Eventos+IPFS	Completo	Limitada	Alta	Limitada
EBSI	Hashes	Solo hashes	Completo	No	Media	Ninguna
ONCHAINID	On-chain	Completa	Ninguno	Sí	Baja	Directa
SSIoBC	On-chain	Completa	Compl.+Ext.	Sí	Media	Directa

II-B. Brechas críticas

El análisis comparativo revela brechas fundamentales [13]. Primero, ninguna implementación combina cumplimiento W3C con almacenamiento completo on-chain a coste razonable: ERC-1056 y LACChain dependen de reconstrucción off-chain; EBSI almacena solo hashes requiriendo mediación API; ONCHAINID utiliza estándares pre-W3C. Segundo, la resolución en tiempo real dentro de arquitecturas descentralizadas permanece elusiva: los sistemas basados en eventos incurrir en latencia mediante dependencia de indexadores off-chain, mientras la mediación API de EBSI impide la interacción directa. Tercero, la interoperabilidad directa con contratos inteligentes solo es alcanzable con costes prohibitivos, renunciando a estándares, o introduciendo centralización. Finalmente, ningún sistema ofrece un modelo económico viable que armonice costes razonables con funcionalidad completamente descentralizada y cumplimiento de estándares.




Figura 1. Arquitectura de alto nivel del sistema SSIoBC.

III. ARQUITECTURA SSIoBC

Cada decisión de diseño de SSIoBC responde a una brecha de la Sección II.B: frente a la mediación API y reconstrucción off-chain, autenticación nativa vía origen de transacción; frente al almacenamiento híbrido, almacenamiento on-chain completo con acceso O(1) hash-based; frente a la fragmentación de métodos DID, namespaces jerárquicos en un único contrato W3C-compliant; y frente a proxies actualizables que reintroducen centralización (ONCHAINID), una arquitectura inmutable que preserva las garantías de descentralización.

III-A. Arquitectura modular de cuatro contratos

SSIoBC implementa un sistema modular de cuatro contratos [9]: DidManager como orquestador central que hereda VMStorage (Verification Methods) y ServiceStorage (Service Endpoints) para acceso unificado, y W3CResolver como componente de solo lectura que formatea documentos W3C-compliant. La Fig. 1 ilustra esta arquitectura. DidManager sirve como interfaz principal almacenando metadatos del DID Document (fechas de expiración, controladores), mientras la estructura de herencia habilita gestión completa a través de una única interfaz manteniendo separación limpia entre componentes.

El sistema soporta namespacing multi-método mediante sintaxis extendida *did:method0:method1:method2:id*, con hasta tres segmentos de 10 bytes empaquetados en un único slot de 32 bytes. Por ejemplo, *did:lzpf:main:123bcd* utiliza “lzpf” y “main” como niveles de namespace, permitiendo a las organizaciones crear namespaces aislados donde los identificadores son únicos dentro de su namespace designado. Los identificadores DID se generan mediante hash pseudoaleatorio de los métodos, un valor aleatorio externo, la dirección del emisor y la marca temporal del bloque, eliminando la correlación directa entre DID y dirección de usuario. La arquitectura de almacenamiento emplea indexación hash-based con acceso determinista O(1), consolidando las seis listas W3C de Verification Methods en una única lista con una propiedad *relationships* codificada mediante bitfield, donde cada bit representa una relación diferente, reduciendo significativamente los requisitos de almacenamiento manteniendo compatibilidad completa con el estándar W3C. El sistema incorpora expiración automática de cuatro años renovable con cada operación de escritura, previniendo ataques de identidad fantasma donde un DID expirado podría retener capacidades activas.

III-B. Mecanismo de autenticación nativa

SSI_oBC utiliza la ejecución de transacciones como prueba de control, eliminando esquemas de verificación criptográfica separados [10]. Al crear un DID, el sistema establece automáticamente al originador de la transacción como controlador inicial. La autenticación valida que el origen de la transacción coincida con la dirección Ethereum registrada en los Verification Methods del DID, aprovechando la verificación de firmas ECDSA de Ethereum sin overhead adicional. El sistema soporta hasta cinco controladores por DID mediante arrays de longitud fija, optimizados para eficiencia de almacenamiento blockchain. Esta limitación previene cadenas de delegación ilimitadas y reduce la superficie de ataque, adoptando control auto-soberano por defecto cuando el array permanece vacío, con escenarios multi-controlador recomendados para supervisión institucional o mecanismos de recuperación.

III-C. Integración directa con contratos inteligentes

La arquitectura habilita que cualquier contrato inteligente compatible con la EVM interactúe directamente con DidManager, proporcionando capacidades DID nativas al ecosistema blockchain. Los contratos pueden consultar el estado de autenticación DID para decisiones de control de acceso, validar relaciones de identidad para protocolos multipartita, y recuperar Service Endpoints para comunicación descentralizada mediante llamadas blockchain estándar.

El sistema soporta dos patrones de interacción principales. La interacción directa permite a cualquier entidad autenticada modificar su propio DID Document demostrando propiedad mediante un Verification Method válido —el origen de la transacción debe coincidir con una dirección Ethereum registrada con permisos de relación apropiados. Las modificaciones delegadas habilitan control cross-DID donde una entidad autenticada puede modificar el documento de otro DID, siempre que su DID esté registrado como controlador del DID objetivo.

III-D. Desactivación y reactivación W3C-compliant

SSI_oBC implementa un ciclo de vida completo de desactivación y reactivación conforme al estándar W3C DID Core. La desactivación establece *expiration* = 0, preservando íntegramente los Verification Methods, Service Endpoints y controladores asociados, permitiendo recuperación posterior sin pérdida de información. La reactivación soporta dos modos: en el **modo self**, el propietario demuestra control mediante un Verification Method registrado en el DID desactivado; en el **modo controller**, un DID externo activo registrado como controlador ejecuta la reactivación, proporcionando recuperación delegada para escenarios donde el propietario ha perdido acceso. La eficiencia es notable al modificarse únicamente el campo de expiración sin alterar las estructuras de datos subyacentes.

III-E. Arquitectura dual y autorización cross-DID

SSI_oBC ofrece dos variantes optimizadas compartiendo una base común (DidManagerBase, ServiceStorage, HashUtils). La **variante Full W3C** mantiene soporte completo para Verification Methods con múltiples slots, habilitando múltiples claves y tipos incluyendo *publicKeyMultibase* y *blockchainAccountId* explícitos. La **variante Ethereum-Native** empaqueta

dirección, relaciones y expiración en un único slot de 32 bytes, derivando campos W3C adicionales en tiempo de resolución aprovechando que la dirección Ethereum permite reconstruirlos de forma determinista. La variante Native logra **reducción del 13 % en bytecode** (10.944 vs 12.102 bytes), con ahorros de gas significativos en operaciones de Verification Methods, permitiendo a los desplegados seleccionar la variante óptima para su caso de uso sin sacrificar interoperabilidad ni cumplimiento de estándares. Adicionalmente, la función *isAuthorized()* (v1.2.1) es una función *view* no-reverting que valida relaciones de autorización entre DIDs verificando que ambos están activos, existe un Verification Method válido y la delegación de controlador es correcta, habilitando **control de acceso nativo desde cualquier contrato inteligente** sin coste operacional para consultas off-chain.

IV. VALIDACIÓN EXPERIMENTAL

IV-A. Entorno experimental

La validación aborda tres dimensiones: verificación funcional de corrección de implementación, análisis de rendimiento de costes operacionales, y evaluación comparativa frente a sistemas existentes. Se utilizó el framework Foundry (v0.2.0) con la herramienta de pruebas Forge sobre testnet Ethereum local (Anvil, configurado con parámetros mainnet). Los contratos se compilaron con Solidity 0.8.24 (optimización 200 runs). Las mediciones de gas se obtuvieron mediante el reporting integrado de Forge, garantizando resultados reproducibles en entorno controlado. La evaluación comparativa emplea un framework estructurado abordando seis dimensiones: clasificación de arquitectura, análisis de ubicación de datos, estado de cumplimiento W3C, capacidad de resolución en tiempo real, comparación de eficiencia de gas, y evaluación de interoperabilidad con contratos inteligentes.

IV-B. Cobertura de pruebas

La estrategia de pruebas emplea un enfoque multicapa con **317 pruebas** distribuidas en seis categorías: 258 pruebas unitarias validan la corrección individual de cada función de contrato; 21 pruebas de fuzz verifican el comportamiento ante entradas aleatorias; 15 pruebas de invariantes comprueban propiedades del sistema bajo cualquier secuencia de operaciones; 9 pruebas de integración ejecutan flujos completos del ciclo de vida DID; 8 pruebas de rendimiento establecen benchmarks de consumo de gas; y 6 pruebas de estrés evalúan el comportamiento bajo condiciones extremas.

La cobertura alcanzada supera el **98 % en líneas** de código, **100 % en funciones** y **93,10 % en ramas**, proporcionando alta confianza en la fiabilidad del sistema. La cobertura de ramas refleja caminos defensivos (*require* y *revert*) verificados mediante pruebas específicas de condiciones de error.

IV-C. Consumo de gas por operación

Las mediciones se realizan sobre un DID Document de referencia compuesto por los campos W3C esenciales: identificador de 32 bytes, hasta cinco controladores, un Verification Method inicial (un slot en la variante Native; N slots en la variante Full W3C con *publicKeyMultibase* y *blockchainAccountId* explícitos), cero o más Service Endpoints almacenados como *bytes* dinámicos, y un campo *ex-*

piration (uint256). La Tabla II presenta el consumo de gas medido con datos reales (v1.1.0–v1.2.2).

Tabla II
CONSUMO DE GAS DE OPERACIONES PRINCIPALES (v1.1.0–v1.2.2).

Operación	Gas (mediana)	Múlt. vs ETH*
createDid	283.506	~13,5x
createVm	271.166	~12,9x
deactivateDid	51.696	~2,5x
reactivateDid (self)	48.229	~2,3x
reactivateDid (controller)	68.463	~3,3x
updateController	78.192	~3,7x
updateService	198.389	~9,4x
validateVm	35.446	~1,7x

* Referencia: transferencia básica ETH = 21.000 gas

La creación de DID (283K gas, ~13,5x una transferencia ETH) resulta competitiva considerando que almacena completamente on-chain toda la información del DID Document, comparable a un mint de NFT estándar (~150K–300K gas) pero proporcionando funcionalidad de gestión de identidad completa e interoperable. Las operaciones de desactivación y reactivación destacan por su eficiencia (~2,3–3,3x una transferencia ETH), al requerir únicamente modificación del campo de expiración preservando todas las estructuras de datos subyacentes. La validación de Verification Methods (*validateVm*) es la operación más ligera (35K gas, ~1,7x), habilitando verificaciones de identidad on-chain frecuentes con coste mínimo. La arquitectura hash-based reduce los costes operacionales ~60 % frente a implementaciones naïve basadas en arrays, haciendo económicamente viable el almacenamiento completamente on-chain.

El consumo de gas es independiente del número de Verification Methods o Service Endpoints ya almacenados en el DID Document, gracias al acceso O(1) del esquema hash-based. La variación de gas responde únicamente al *payload* escrito en cada operación: *createDid* tiene coste constante porque instancia metadatos fijos y un único VM por defecto, mientras que *updateService* escala linealmente con la longitud del endpoint al almacenarse como *bytes* dinámicos. En la práctica, un DID Document ampliado con cinco Verification Methods y varios servicios mantiene el mismo coste unitario por operación que uno mínimo. Respecto al despliegue, ambas variantes ocupan menos del 50 % del límite EIP-170 (12.102 y 10.944 bytes), dejando margen sustancial para extensiones futuras.

IV-D. Ventajas comparativas

SSIoBC logra eficiencia comparable a alternativas basadas en eventos e inferior a ONCHAINID (~500K+ gas), ofreciendo simultáneamente cumplimiento W3C completo, resolución en tiempo real, autorización cross-DID nativa y soporte multi-namespace —propiedades que ninguna otra implementación ofrece conjuntamente. A diferencia de la reconstrucción basada en eventos de ERC-1056, SSIoBC habilita resolución mediante consultas directas al estado blockchain; a diferencia de la mediación API de EBSI, preserva acceso permissionless; y a diferencia de los proxies actualizables de ONCHAINID, garantiza inmutabilidad. La función *isAuthorized()* transforma SSIoBC en una infraestructura de autorización descentralizada invocable desde cualquier contrato inteligente.

V. CONCLUSIONES

Este artículo ha presentado SSIoBC, un sistema de gestión de DID Documents completamente on-chain que resuelve los compromisos arquitectónicos de las implementaciones existentes combinando autenticación nativa, namespaces jerárquicos y almacenamiento on-chain inmutable, propiedades que ningún otro sistema combina simultáneamente. Respecto a la versión inicial [14], este trabajo aporta tres contribuciones adicionales: desactivación/reactivación W3C-compliant con modos *self* y *controller*, una arquitectura dual con 13 % de reducción en bytecode en la variante Ethereum-Native, y la función *isAuthorized()* para autorización cross-DID desde cualquier contrato inteligente. La validación experimental confirma la viabilidad: 317 pruebas con cobertura superior al 98 %, 283K gas por creación de DID y bytecode por debajo del 50 % del límite EIP-170, dejando margen para futuras extensiones.

Como trabajo futuro, la prioridad es implementar *Verifiable Claims* on-chain que hereden las propiedades *trustless* de SSIoBC, seguida de frameworks de confianza descentralizados. El código fuente está disponible en <https://github.com/MiguelLZPF/SSIoBC-did> y <https://github.com/MiguelLZPF/SSIoBC-did-examples>.

AGRADECIMIENTOS

Este trabajo ha sido financiado por la Agencia Estatal de Investigación (AEI) a través del proyecto SITED: “Semantically-enabled Interoperable Trustworthy Enriched Data-spaces” (Ref. PID2021-125725OB-I00) financiado por MICIU/AEI/10.13039/501100011033 y por FEDER, UE.

Declaración: Este artículo ha sido redactado con asistencia de herramientas de inteligencia artificial (IA).

REFERENCIAS

- [1] P. Braendgaard y J. Torstensson, “ERC-1056: Ethereum Lightweight Identity,” *Ethereum Improvement Proposals*, 2018. [En línea]. Disponible: <https://eips.ethereum.org/EIPS/eip-1056>
- [2] M. Allende López y S. Cerón, “LACChain ID Framework,” Inter-American Development Bank, 2021.
- [3] European Commission, “European Blockchain Services Infrastructure (EBSI),” 2024. [En línea]. Disponible: <https://ec.europa.eu/digital-building-blocks/sites/display/EBSI/Home>
- [4] ONCHAINID, “ONCHAINID Documentation,” 2024. [En línea]. Disponible: <https://docs.onchainid.com/>
- [5] M. Sporny *et al.*, “Decentralized Identifiers (DIDs) v1.0,” *W3C Recommendation*, 2022. Disponible: <https://www.w3.org/TR/did-core/>
- [6] C. Allen, “The Path to Self-Sovereign Identity,” 2016. [En línea]. Disponible: <https://www.lifewithalacrity.com/article/the-path-to-self-sovereign-identity/>
- [7] A. Mühle, A. Grüner, T. Gayvoronskaya y C. Meinel, “A survey on essential components of a self-sovereign identity,” *Computer Science Review*, vol. 30, pp. 80–86, 2018.
- [8] R. A. Pava-Díaz, J. Gil-Ruiz y D. A. López-Sarmiento, “Self-sovereign identity on the blockchain: contextual analysis and quantification of SSI principles implementation,” *Frontiers in Blockchain*, vol. 7, 2024. doi: 10.3389/fbloc.2024.1443362.
- [9] Y. Liu, Q. Lu, H.-Y. Paik, X. Xu y S. Chen, “Design Patterns for Blockchain-based Self-Sovereign Identity,” en *Proc. European Conf. Pattern Languages of Programs*, 2020.
- [10] P. Mell, J. Dray y J. Shook, “Smart Contract Federated Identity Management without Third Party Authentication Services,” en *Proc. Open Identity Summit*, 2019.
- [11] S. Pflanzner, A. Varga y T. Gyimóthy, “Latency analysis of blockchain-based SSI applications,” *Applied Sciences*, vol. 12, no. 12, p. 5888, 2022.
- [12] D. Schumm, K. O. E. Müller y B. Stiller, “Are We There Yet? A Study of Decentralized Identity Applications,” *arXiv preprint arXiv:2503.15964*, 2025.
- [13] H. Halpin, “Deconstructing the Decentralization Trilemma,” *arXiv preprint arXiv:2008.08014*, 2020.
- [14] M. Gómez-Carpena, J. Lanza y L. Sánchez, “Towards full Digital Sovereignty on-chain enabled by smart contract-based DID management,” en *Proc. Int. Conf. Digital Sovereignty (ICDS 2025)*, Oslo, Noruega, oct. 2025. Springer, a publicarse en mayo 2026. [En línea]. Disponible: <https://link.springer.com/book/9783032215239>

Identificación y anonimización de entidades nombradas en fuentes de información no estructurada para su uso en detección de ingeniería social

Carlos Jimeno Miguel
Universidad Pública de Navarra
Pamplona, España
carlos.jimeno@unavarra.es

Raúl Orduna Urrutia
Universidad Pública de Navarra // Vicomtech
Pamplona, España // San Sebastián, España
raul.orduna@unavarra.es // rorduna@vicomtech.org

Francesco Zola
Vicomtech
San Sebastián, España
fzola@vicomtech.org

Resumen—Este estudio aborda el desafío de crear conjuntos de datos para el análisis del cibercrimen cumpliendo con el RGPD y la Ley Orgánica 10/1995 del Código Penal. Se propone un sistema de recolección de información multimodal desde Telegram (texto, audio e imágenes), modelos de transcripción de voz a texto con mejora de señal, y la evaluación de soluciones de Reconocimiento de Entidades Nombradas (NER) basadas en Microsoft Presidio y arquitecturas Transformer. Los resultados muestran que Wav2Vec ofrece el mejor equilibrio precisión-velocidad en transcripción, mientras que el modelo BERT *fine-tuned* supera a Presidio en identificación de entidades. Se proponen además métricas originales de anonimización que evalúan la coherencia estructural del texto resultante.

Index Terms—Telegram, crawling, dark web, crimen organizado, audio, anonimización, NER

Tipo de contribución: Investigación original

I. INTRODUCCIÓN

La democratización del cibercrimen mediante el modelo *Crime-as-a-Service* (CaaS) ha generado un incremento exponencial en la frecuencia y sofisticación de los ataques. El proyecto europeo *SafeHorizon* aborda esta amenaza desarrollando herramientas de monitorización de actividades criminales digitales. Esta actividad plantea una tensión crítica entre protección de datos (RGPD [1], LO 10/1995 [2]) y utilidad analítica: una anonimización excesiva destruye las relaciones entre entidades necesarias para detectar patrones de ingeniería social, mientras que una insuficiente incumple la normativa. Este trabajo propone metodologías replicables para extraer y anonimizar correctamente estructuras relacionales de actividades fraudulentas a partir de fuentes no estructuradas (texto, audio e imágenes) que cumplan con las restricciones de las legislaciones anteriores. Dichos hallazgos servirán para un posterior análisis de este tipo de fraudes y su validación por parte de las fuerzas y cuerpos de seguridad de los estados miembros.

II. ESTADO DEL ARTE Y MÉTODOS DE EVALUACIÓN

Las *Privacy-Enhancing Technologies* (PETs) incluyen técnicas como la pseudonimización, el enmascaramiento de datos, el cifrado, la generalización y la privacidad diferencial, entre otras. La anonimización, objeto central de este trabajo, busca la eliminación irreversible de datos personales identificables. La anonimización de datos personales ha ido

evolucionando desde escenarios más sencillos de controlar con datos tabulares hasta textos donde no existe una jerarquización clara. En estas fuentes no estructuradas, el reconocimiento de entidades nombradas (NER) ha supuesto un avance significativo aportando desde reconocimiento de expresiones regulares hasta modelos de *machine learning*, con propuestas basadas en CRF, LSTM/ELMo y Transformers [3], [4], [5], [6], [7].

Este trabajo evalúa Microsoft Presidio y un modelo BERT *fine-tuned*, seleccionando el mejor según *f1 score* [8]. La existencia de mensajes multimedia en este tipo de fuentes genera la necesidad de adaptar estas técnicas al recabado de imágenes y audios. Para el caso de las imágenes, se integrará en el flujo un mecanismo descriptor de imágenes y un modelo de OCR. En el caso del audio, se comparará el rendimiento de diferentes modelos de transcripción de audio aplicando un sistema de realce de la voz y reducción de ruido basado en estudios como el de A. Aben *et al.* [9], siempre estudiando el *Word Error Rate* (WER) [10] con pesos 0.10 para inserciones y 0.45 para borrados y sustituciones.

Para evaluar la calidad de la anonimización conseguida se proponen cuatro métricas originales. La **pérdida de información** mide la diferencia de entropía de Shannon entre el texto original X y el anonimizado X' :

$$IL(X, X') = E(X) - E(X')$$

Donde valores negativos indican generación de nueva información y positivos pérdida neta. La **consistencia** $C \in [0, 1]$ evalúa si cada entidad (*text*) del conjunto total de tokens (T) siempre se anonimiza igual:

$$C = \frac{1}{|T|} * \sum_{t \in T} \frac{\text{Conversiones correctas de } t}{\text{Total de apariciones de } t}$$

El **grado de colisión** $G \in [0, 1]$ mide la proporción de *hashes* (h) únicos dentro del conjunto total (H):

$$G = \frac{|\{h \in H : |G_h| = 1\}|}{|H|}$$

Donde G_h representa cada el conjunto de *tokens* que generan dicho *hash*, y se define como:

$$G_h = \{t \in T : f(t) = h\}$$

La **tasa de error** que combina ambas métricas anteriores asignando un peso α a cada una de ellas:

$$\text{Error} = 1 - (\alpha C + (1 - \alpha)G)$$

Finalmente, la **preservación de correlación promedio** cuantifica la similitud entre *hashes* generados para el mismo *token* en textos distintos, mediante la distancia de Levenshtein (L) [11]. Siendo $f : T \rightarrow H$ la función que genera el *hash* de anonimización de un texto, podemos definir la preservación de correlación promedio como:

$$\text{Avg correlation} = \frac{1}{|\{H_A \cup H_B\}|} * \sum_{t \in T} 1 - \left(\frac{L(f_a(t), f_b(t))}{\max(f_a(t), f_b(t))} \right)$$

III. MARCO DE EXPERIMENTACIÓN

Se presenta un primer prototipo, ya que no existían algoritmos o herramientas previas, y que sirve de prueba de concepto para recabar inteligencia de fuentes sin un sistema general de búsqueda. A continuación, se describirá la integración de dos nuevas herramientas de identificación de entidades, una propuesta de arquitectura del módulo de reconocimiento de *Microsoft Presidio*, y un modelo propio basado en *Transformers*. Por último, se expondrá la integración de un nuevo motor de anonimización, basado en el módulo de anonimización de *Microsoft Presidio*, para, posteriormente realizar una comparativa empleando las métricas descritas en el apartado anterior de: este motor, la implementación existente en el centro de investigación y su revisión adaptada al modelo basado en *Transformers* desarrollado.

III-A. Obtención de inteligencia a través de Telegram

Dado que los buscadores de *Telegram* no facilitan la localización de actividades ilícitas, se desarrolla un método OSINT basado en *Google dorking* con la cláusula `site:t.me` combinada con términos de búsqueda relevantes (e.g *Carding*, *Ransomware*). Los recursos públicos se recaban mediante *web crawling*; los privados mediante la librería *Telethon*, que implementa la API oficial de *Telegram* en python. Para respetar los umbrales de uso se introduce un retardo aleatorio de 30–60 segundos por mensaje.




Figura 1: Diagrama de secuencia del recabado de mensajes en *Telegram*

III-B. Transcripción de audio

Se comparan las versiones ligeras de tres modelos preentrenados sobre 3000 muestras del dataset *espnets/yodas-granary* [12]: **parakeet-tdt-0.6b-v3** (Nvidia), **whisper-small** (OpenAI) y **wav2vec2-base-960h** (Meta). El preprocesamiento de señal emplea el modelo VAD *pyannote/segmentation-3.0* y la librería *noisereduce* para suprimir el ruido en las regiones sin voz activa.

III-C. Identificación de entidades

Para *Presidio* se propone una arquitectura de tres pasos: localización de expresiones regulares ya conocidas por el centro, procesado del texto mediante un modelo general GLiNER [13] y posteriormente por un modelo BERT preentrenado [14], evaluados todos los pasos sobre el dataset *text-anonymization-benchmark* [15], consistente en textos judiciales en formato libre del Tribunal Europeo de Derechos Humanos (ECHR). Para el modelo *Transformer* se parte de *google/bert-base-cased* [16], con un primer *fine-tuning* sobre *OntoNotes5* [17] validado, luego sobre los textos de formato libre anteriores, y un segundo *fine-tuning* específico sobre datasets del dominio del cibercrimen. Estos datasets consisten en el preprocesado de tres conjuntos de datos (*Josephgflowers/CENSUS-NER-Name-Email-Address-Phone* [18], *Josephgflowers/PII-NER* [19] y *ai4privacy/pii-masking-400k* [20]) donde el resultado ha generado un conjunto con las clases ADDRESS, CREDITCARDNUMBER, EMAIL, IDCARDNUM, NAME, PASSPORT y PHONE.

Los hiperparámetros empleados para las puestas a punto realizadas sobre el modelo son: *learning rate* 2×10^{-5} , *batch size* 16, 3 épocas y *weight decay* 0.1.

III-D. Anonimización

Las predicciones del modelo NER se deben formatear bajo la clase *RecognizerResult* de *Presidio*. En el caso del módulo de identificación de *Presidio*, esta conversión es inmediata, sin embargo, para el modelo BERT *fine-tuned* es necesario retirar el texto localizado, su posición de inicio y final y la confianza con la que se categoriza dicha entidad, y convertirlos a la misma clase anterior.

Una vez formateado, se define el método de anonimización que empleará el módulo. En este caso se empleará el método de *sustitución*, consistente en generar una cadena de texto basada en la predicción y el valor textual anonimizado (*clase-hash*), coherente con el procedimiento de los empleado actualmente por los socios del proyecto. Se comparan tres métodos: el *Transformer fine-tuned*, *Presidio* y el método *In-line* actual del centro.

IV. DISCUSIÓN DE LOS RESULTADOS

La integración de *Telegram* y la transcripción de audio amplía las fuentes de inteligencia de cuatro; texto e imágenes en páginas de la *dark web* y *shallow clear web*, a nueve; añadiendo audio a todas las fuentes e imagen y texto a *Telegram*. A continuación se presentan los resultados por módulo.

IV-A. Transcripción de mensajes de audio

La Tabla I resume el WER y el tiempo de ejecución de cada modelo, con y sin preprocesamiento de la señal.

Tabla I: Resultados de transcripción: WER y tiempo de ejecución

Modelo	WER orig.	WER filtrado	Tiempo (s)
Parakeet	0.16	0.16	7215.63
Wav2Vec	0.21	0.24	111.93
Whisper	0.37	0.40	2100.89

Parakeet obtiene la mejor precisión (WER 0.16), pero *Wav2Vec* es 64 veces más rápido manteniendo un 75 % de aciertos. El filtrado de señal resulta contraproducente para *Whisper* y *Wav2Vec*, por lo que no se recomienda su uso con estos modelos.

IV-B. Identificación de entidades nombradas

La Tabla II muestra el *f1 score* y el tiempo de ejecución obtenidos por *Microsoft Presidio* bajo dos configuraciones de hardware. Aunque *Presidio* es sencilla de desplegar en

Tabla II: Resultados de NER con Microsoft Presidio

Configuración	Muestras	F1	Tiempo
Equipo no dedicado	100	0.74	t_{base}
Clúster HPC	225	0.79	$\approx t_{base}/2 \rightarrow \text{exp.}$

entornos de producción, no presenta una mejora significativa en precisión al incrementar los recursos, y el tiempo de ejecución crece exponencialmente a partir de un número modesto de muestras, por lo que no resulta la mejor solución para la fase de identificación.

La Tabla III resume los resultados del modelo basado en BERT a lo largo de las tres etapas experimentales.

Tabla III: Resultados del modelo BERT por etapa experimental

Etapas	Dataset	F1
Viabilidad	CoNLL-2003	0.94
Fine-tuning (train)	OntoNotes5	0.97
Fine-tuning (val.)	ECHR libre	0.93
Cibercrimen (global)	Datasets PII	0.96
Cibercrimen (minorit.)	Datasets PII	0.53

El estudio de viabilidad se aproxima al 0.95 reportado por D. Asimopoulos *et al.* [3], validando la elección del modelo base. El primer *fine-tuning* demuestra robustez en contextos no estructurados a pesar de que los textos superan el límite de 512 tokens. La puesta a punto específica para cibercrimen expone que, aunque el rendimiento sobre las clases minoritarias (PASSPORT, IDCARDNUM) cae debido al gran desbalance de clases y la alta variabilidad en los formatos de las entidades según el país de origen, el modelo tiene una tasa de acierto global considerable.

IV-C. Anonimización de entidades nombradas

La Tabla IV presenta las métricas de anonimización para los tres métodos evaluados.

Tanto el método *Transformer* como *Presidio* alcanzan consistencia perfecta y tasa de error nula, mientras que los valores negativos de pérdida de información indican que

Tabla IV: Métricas de anonimización por método

Método	IL	C	G	Error	Corr.
Transformer	-0.16	1.00	1.00	0.00	0.24
Presidio	-0.17	1.00	1.00	0.00	0.18
In-line	+0.26	0.00	1.00	0.50	0.05

ambos métodos introducen nuevos *tokens* aleatorios durante la anonimización. El método *In-line* presenta una pérdida de información positiva (pérdida neta de información original), consistencia nula y una tasa de error de 0.50, lo que lo hace inadecuado para aplicaciones que requieran garantías de anonimización robusta y reproducible. Cabe señalar que los valores objetivo óptimos de estas métricas pueden variar en función de los requisitos concretos de la aplicación, por lo que la elección del método debe estar siempre informada por el contexto de uso.

V. SELECCIÓN DEL MEJOR MÉTODO

Con base en los resultados experimentales, se propone el siguiente *pipeline* integrado para la generación del *dataset* de mayor calidad, destinado a las fases posteriores de análisis de comportamientos y su visualización:

1. **Obtención de fuentes de inteligencia:** Herramientas de *crawling web* para la recopilación automática de enlaces de invitación a grupos y canales de mensajería, sobre los cuales posteriormente se realiza la búsqueda y monitorización de contenido ilegal y posibles accesos a *dark markets*. Adicionalmente, se emplea el mecanismo de OCR desarrollado por los socios del proyecto para la extracción de texto de imágenes capturadas, constituyendo así la infraestructura de captura en fuentes no estructuradas.
2. **Transcriptor de audio:** Modelo *Wav2Vec*, seleccionado por su balance óptimo entre precisión y velocidad de procesamiento, adecuado para la transcripción en tiempo real de fuentes de audio.
3. **Identificador de entidades de cibercrimen:** Modelo BERT *fine-tuned* sobre entidades específicas del dominio (cuentas financieras, identificadores personales, correos electrónicos, números de teléfono y localizaciones), capaz de establecer relaciones contextuales entre entidades.
4. **Anonimizador:** Sistema basado en *Transformers* con método de sustitución por *placeholders* (formato *clase-hash*), garantizando consistencia, trazabilidad y ausencia de colisiones en el procesamiento de datos sensibles.

Esta configuración maximiza la cantidad y calidad de datos procesados, minimizando tiempos de procesamiento y tasas de error, generando así el *dataset* óptimo para las subsiguientes fases del proyecto.

VI. CONCLUSIONES Y TRABAJO FUTURO

El presente trabajo ha logrado desarrollar con éxito una serie de módulos dedicados para la obtención, procesamiento y anonimización de fuentes de inteligencia no estructuradas en el ámbito del cibercrimen, incrementando significativamente las capacidades analíticas del centro tecnológico. El *pipeline* propuesto amplía el número de fuentes de inteligencia disponibles de cuatro a nueve, incorporando la transcripción de

audio y la recolección de datos de *Telegram* a la infraestructura existente. El modelo *Wav2Vec* emerge como la solución de transcripción más equilibrada, ofreciendo un rendimiento cercano al tiempo real a una fracción del coste en tiempo de procesamiento respecto a alternativas de mayor precisión. El modelo NER basado en BERT, puesto a punto sobre entidades específicas del cibercrimen, alcanza *f1 scores* competitivos en escenarios no estructurados reales, superando a *Microsoft Presidio* tanto en precisión como en escalabilidad. Por último, tanto el método de anonimización basado en *Transformers* como *Presidio* superan ampliamente al método *In-line* actual del centro, proporcionando sustituciones consistentes, sin colisiones y con tasa de error nula.

Dado que la manera de proceder del proyecto ha sido la investigación y desarrollo de cada módulo por separado se presentan ciertas líneas de trabajo futuro.

En primer lugar, resulta interesante integrar todos los componentes en un solo flujo completo capaz de obtener las fuentes de información, analizarlas y guardar los resultados del análisis anonimizados.

En el caso de la extracción de contenido se plantean varias líneas de trabajo. Primero, realizar un estudio más a fondo de las normativas de diferentes plataformas de mensajería, redes sociales y *dark nets* (que podrían tener condiciones de uso diferentes) para integrar más fuentes de inteligencia al módulo de extracción de información cumpliendo con los términos de servicio que expongan. Segundo, extender la búsqueda de enlaces a recursos privados a través de otros motores de búsqueda o indexadores de contenido de la *shallow clear web*, a través de sus APIs o herramientas. Tercero, el uso de un sistema descriptor de imágenes, *image captioning*, más allá del OCR que presenta actualmente el consorcio *SafeHorizon* para generar grafos de conocimiento más detallados.

Por último, como se ha comentado en la sección anterior, persisten desafíos relacionados con el desbalance de clases en los *datasets* empleados y la ausencia de entidades como direcciones IP, IBANs y direcciones *blockchain*, cuya integración, como ya se ha propuesto pero no se ha integrado, se puede realizar, por ejemplo, mediante la generación sintética con la librería *Faker* para enriquecer la robustez del sistema en todos los tipos de entidades relevantes para el análisis de cibercrimen.

AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por el Programa de Investigación e Innovación Horizonte 2020 de la Unión Europea en el marco del proyecto SAFEHORIZON (Acuerdo de subvención n.º 101168562). El contenido de este artículo no refleja la opinión oficial de la Unión Europea. La responsabilidad de la información y las opiniones expresadas en él recae íntegramente en los autores.

REFERENCIAS

- [1] Parlamento Europeo y Consejo de la Unión Europea, "Reglamento (ue) 2016/679 del parlamento europeo y del consejo, de 27 de abril de 2016, relativo a la protección de las personas físicas en lo que respecta al tratamiento de datos personales y a la libre circulación de estos datos," Diario Oficial de la Unión Europea, 2016, accedido: 23-jun-2025. [Online]. Available: <https://www.boe.es/doue/2016/119/L00001-00088.pdf>
- [2] Jefatura del Estado, "Ley Orgánica 10/1995, de 23 de noviembre, del Código Penal," Nov. 1995, bOE-A-1995-25444. [Online]. Available: <https://www.boe.es/eli/es/lo/1995/11/23/10/con>
- [3] D. Asimopoulos, I. Siniosoglou, V. Argyriou, T. Karamitsou, E. Fountoukidis, S. K. Goudos, I. D. Moscholios, K. E. Psannis, and P. Sargiannidis, "Benchmarking advanced text anonymisation methods: A comparative study on novel and traditional approaches," in *2024 13th International Conference on Modern Circuits and Systems Technologies (MOCAST)*, 2024, pp. 1–6.
- [4] D. Asimopoulos *et al.*, "Evaluating the efficacy of AI techniques in textual anonymization: A comparative study," in *2024 7th International Balkan Conference on Communications and Networking (BalkanCom)*, Ljubljana, Slovenia, 2024, pp. 242–246.
- [5] F. Hassan, J. Domingo-Ferrer, and J. Soria-Comas, "Anonymization of unstructured data via named-entity recognition," in *Modeling Decisions for Artificial Intelligence (MDAI 2018)*, ser. Lecture Notes in Computer Science, V. Torra, Y. Narukawa, I. Aguiló, and M. González-Hidalgo, Eds. Cham: Springer, 2018, vol. 11144, pp. 313–324.
- [6] I. Siniosoglou *et al.*, "Enhancing text anonymisation: A study on CRF, LSTM, and ELMo for advanced entity recognition," in *2024 Panhellenic Conference on Electronics & Telecommunications (PACET)*, Thessaloniki, Greece, 2024, pp. 1–6.
- [7] S. Patchipala, "Data anonymization in ai and ml engineering: Balancing privacy and model performance using presidio," *IRE Journals*, vol. Volume 6, p. 13, 04 2023.
- [8] T. Tigerschild, "What is accuracy, precision, recall and f1 score?" *Labelf Blog*, Nov. 2022, accedido: 23-jun-2025. [Online]. Available: <https://www.labelf.ai/blog/what-is-accuracy-precision-recall-and-f1-score>
- [9] A. Aben, G. Kazbekova, Z. Ismagulova, and G. Ibrayeva, "Audio-to-text translation for the hard of hearing: A whisper model-based study," *Scientific Journal of Astana IT University*, pp. 24–36, 2025.
- [10] J. D. Marangon, "How to calculate the word error rate in python," Nov. 2023, accedido: 23-jun-2025. [Online]. Available: <https://medium.com/@johnidouglassmarangon/how-to-calculate-the-word-error-rate-in-python-ce0751a46052>
- [11] A. D. Prieto, "Distancia de levenshtein como clasificador de textos," Proyecto de Fin de Máster, Universidade de Santiago de Compostela, Santiago de Compostela, España, Feb. 2023, directores: Jose Ameijeiras Alonso y María José Ginzo Villamayor. Lectura: 16-feb-2023 (online). [Online]. Available: http://eio.usc.es/pub/mte/descargas/ProyectosFinMaster/Proyecto_2142.pdf
- [12] N. R. Koluguri, M. Sekoyan, G. Zelenfroynd, S. Meister, S. Ding, S. Kostandian, H. Huang, N. Karpov, J. Balam, V. Lavrukhin, Y. Peng, S. Papi, M. Gaido, A. Brutti, and B. Ginsburg, "Granary: Speech recognition and translation dataset in 25 european languages," 2025. [Online]. Available: <https://arxiv.org/abs/2505.13404>
- [13] U. Zaratiana, N. Tomeh, P. Holat, and T. Charnois, "Gliner: Generalist model for named entity recognition using bidirectional transformer," 2023. [Online]. Available: <https://arxiv.org/abs/2311.08526>
- [14] D. Flegner, T. Khatri, F. Strobel, and R. Krestel, "bert-large-cased-finetuned-conll03-english," Hugging Face Model Hub, dbmdz, 2023, [Online]. Available: <https://huggingface.co/dbmdz/bert-large-cased-finetuned-conll03-english> (Last accessed: June 23, 2025).
- [15] I. Pilán and P. Lison, "Text anonymization benchmark (tab) v1.0," Hugging Face Datasets, Apr. 2025, [Online]. Available: <https://huggingface.co/datasets/ildpil/text-anonymization-benchmark> (Last accessed: June 23, 2025).
- [16] Google, "bert-base-cased," Hugging Face Model Hub, 2025, accedido: 28-ago-2025. [Online]. Available: <https://huggingface.co/google-bert/bert-base-cased>
- [17] E. Hovy, M. Marcus, M. Palmer, L. Ramshaw, and R. Weischedel, "OntoNotes: The 90 % solution," in *Proceedings of the Human Language Technology Conference of the NAACL, Companion Volume: Short Papers*. New York City, USA: Association for Computational Linguistics, Jun. 2006, pp. 57–60. [Online]. Available: <https://aclanthology.org/N06-2015>
- [18] Josephgflowers, "Census-ner-name-email-address-phone," <https://huggingface.co/datasets/Josephgflowers/CENSUS-NER-Name-Email-Address-Phone>, 2025, dataset en formato CSV en inglés; contiene más de 1 M de registros, incluye NER, correo, teléfono, dirección; licencia MIT.
- [19] —, "Pii-ner," <https://huggingface.co/datasets/Josephgflowers/PII-NER>, 2025, dataset en formato CSV (2.7 K aprox. filas en split "train"); licencia MIT.
- [20] Ai4Privacy, "pii-masking-400k," <https://huggingface.co/datasets/ai4privacy/pii-masking-400k>, 2025, dataset en formatos JSON en inglés, francés, alemán; múltiples tareas: clasificación de tokens, QA, etc.; licencia heredada según LICENSE.md.

On the Practical Viability of Local Agentic Language Models for Android Security Analysis

Héctor Padín-Torrente
Gradiant
Vigo, Spain
hpadin@gradiant.org

Ines Ortega-Fernandez
Gradiant
Vigo, Spain
iortega@gradiant.org

Abstract—This study evaluates the viability of deploying smaller, locally hosted LLMs within an agent-based architecture equipped with specific Android security analysis tools. Using this agentic framework, an evaluation is conducted to assess whether smaller, locally deployed LLMs can achieve performance comparable to state-of-the-art cloud models during the analysis of vulnerabilities in Android APKs. Results show that the local model, *Qwen3-Coder:30B*, achieves performance comparable to *GPT-5.2*, in task completion rates of 84.62% and 87.18%, respectively. In addition, local deployments demonstrate improved execution efficiency and, under sustained workloads, offer a favorable cost profile when amortized over time.

Index Terms—Android Security, Local Large Language Models, Agent Architecture.

Type of contribution: *Original research*

I. INTRODUCTION

Android applications remain a primary target for security analysis due to their widespread adoption and the increasing sophistication of mobile threats. While Large Language Models (LLMs) demonstrate significant potential to automate vulnerability analysis, most existing approaches suffer from two primary limitations: they either rely on direct LLM interaction without any orchestration or tool guidance, or they depend on large, proprietary cloud models, raising concerns about data privacy and compliance [1].

To address these challenges, this work adopts an agent-based architecture for Android security analysis with a set of reverse-engineering and semantic analysis tools. This framework enables the model to (i) obtain high-level application data, (ii) perform semantic queries over application data, and (iii) inspect code artifacts.

The primary objective of this work is to empirically evaluate whether smaller, locally deployed LLMs can serve as a practical, viable alternative to cloud APIs for Android security analysis when orchestrated through an agentic framework. To this end, the study addresses the following research questions:

- R1: Can local LLMs match the performance (task completion and time taken) of cloud LLMs when equipped with an appropriate tool-set?
- R2: What approach is most economically viable in today's organizational landscape?

The remainder of this paper is organized as follows. Section II establishes the background and related work. Section III details the proposed architecture. Section IV presents the methodology and evaluation. Finally, Section V concludes the paper, with Section VI identifying key areas for future research.

II. BACKGROUND AND RELATED WORK

Recent advances in LLMs have demonstrated significant potential in augmenting software security, particularly in code comprehension, and vulnerability detection [2], [3]. Specifically, regarding Android malware detection, in Priambodo et al. [4], authors present a fine-tuned LLM tailored to generate static analysis reports from extracted APK features of public datasets and benchmarks. Similarly, Walton et al. [5], authors introduce summarization chains and prompt engineering to perform Android malware categorization with GPT-4o-mini.

Nevertheless, these approaches frequently fail when confronted with complexities inherent to Android APKs, such as complex cross-file dependencies or massive context windows. To overcome these limitations, recent literature demonstrates that integrating external tools, Retrieval-Augmented Generation (RAG), and agentic orchestration significantly augments model reasoning [6], [7]. For instance, in Wang et al. [8], the authors introduce an agentic framework equipped with specialized toolchains to uncover and validate Android security flaws. While this work demonstrates the technical feasibility of agent-driven analysis, its dependence on proprietary cloud models and lack of cost evaluation leave the economic implications of deploying such systems entirely unexplored.

Assuming a threat model where reliance on third-party cloud APIs compromises the confidentiality of sensitive application data, the novelty of our proposal is twofold. First, we introduce an autonomous, local agentic framework to ensure data sovereignty during security analysis. Second, we provide a rigorous analysis of its practical deployment viability compared to standard cloud models. By measuring the trade-offs in both vulnerability discovery rates and economic feasibility, this work offers empirical evidence and practical guidance for organizations considering the adoption of local security agents.

III. PROPOSED AGENTIC DESIGN

The proposed design is based on a graph-based conversational agent for Android security analysis, enabling structured reasoning over application artifacts. Figure 1 illustrates the architecture of the proposed agentic platform, which is organized into four main layers: APK ingestion, knowledge indexing, agentic reasoning, and user interaction. This framework is exposed to the analyst through an interactive user interface.

APK Ingestion

Since LLMs cannot interpret raw binary data, the ingestion pipeline focuses on transforming APK artifacts into struc-




Figure 1: Architecture of the proposed agentic Android security analysis framework.

tured, textual representations. Each APK is decompiled to extract application’s resources and Smali code. Then, the high-level Java source code is reconstructed, providing the semantic clarity necessary for LLMs to perform complex code analysis. The APK is also processed by static analysis tools, and the resulting report is ingested into a vector database to enable semantic retrieval across security findings. In parallel, the Manifest file is parsed and ingested into the same vector store.

Tool Execution

The Tool Execution Layer provides the mechanism for the agent to interact with external environments. It parses the agent’s structured commands (e.g., JSON or XML), executes the requested tools, and serializes the outputs. These outputs are then injected back into the agent’s context window. This layer exposes a set of domain-specific tools to the agent:

- 1) **Manifest Inspection Tool:** Extracts metadata from the Android manifest.
- 2) **Semantic Security Query Tool:** Performs vector-based retrieval over indexed security findings stored in the vector database.
- 3) **Code Pattern Search Tool:** Executes regex-based searches over decompiled Java and Smali code to locate sensitive patterns.
- 4) **Source File Inspection Tool:** Retrieves and annotates decompiled source files with line numbers to enable precise inspection.

Agentic Workflow

The proposed agentic workflow, as depicted in Figure 2, implements a closed-loop, finite-state conversational workflow that maintains structured context for multi-step reasoning. This workflow is composed of an agent node, dedicated tool execution nodes, and conditional routing logic. Within this design, the LLM autonomously decides when to invoke tools and interprets their outputs.

IV. EVALUATION

This section presents the experimental results obtained from evaluating the performance of local and cloud LLMs




Figure 2: Workflow of the agentic system.

within the agentic framework. Specifically, we compare a local *Qwen3-Coder:30B* model, selected for its balance of agentic reasoning with hardware constraints, deployed on an NVIDIA H100, against a cloud-based *GPT-5.2* baseline with reasoning “Highest” (see model documentation). *GPT-5.2* was chosen as the cloud representative because it embodies the current commercial state-of-the-art in reasoning and agentic performance; by selecting these specific models, our study aims to compare the best available options for each deployment strategy.

The evaluation focuses on task completion, execution time, and cost analysis, with results organized according to the two research questions defined in the introduction. To ensure reproducibility and a controlled experimental environment, we utilize three CTF-style APKs: *InsecureShop* [9], *Insecure-Bankv2* [10], and *InjuredAndroid* [11], which cover a broad section of the OWASP Mobile Top 10 and provide a reliable baseline evaluation.

Task Design and Completion Metrics

Each evaluation task consists of an user query requiring the agent to identify a vulnerability within the APK. The ground truth for each task was pre-validated using both public writeups and manual validation. This ensures that while the queries are analogous in their lack of explicit hints, the agent’s success is measured against a verified baseline.

The tasks present in each APK were categorized according to increasing difficulty levels:

- **Easy:** corresponds to straightforward vulnerabilities that are directly observable in the source code or manifest. An example of this category would be hardcoded credentials or sensitive configuration values which can be identified through simple inspection of the decompiled source code.
- **Medium:** corresponds to tasks that require contextual reasoning across multiple code locations or API usages. An example would be identifying an authentication vulnerability which requires correlating the login activity with API calls.
- **Hard:** corresponds to complex, multi-step analysis tasks involving cross-file reasoning or the correlation of manifest settings with runtime behavior. An example would be identifying exported components declared in the manifest with dynamically invoked activities.

Table I summarizes the distribution of evaluation tasks per application by difficulty level.

Task completeness was defined by the agent’s ability to provide a recovered flag, identify a precise file/line location, or

App Name	Easy	Medium	Hard	Total
<i>InsecureShop</i> [9]	5	6	4	15
<i>InsecureBankv2</i> [10]	7	5	4	16
<i>InjuredAndroid</i> [11]	2	3	3	8

Table I: Distribution of evaluation tasks per application, grouped by difficulty level.

Model	Pass Rate	Avg. Time	Avg. Tools
GPT-5.2	87.18%	35.19	10.46
Qwen3-Coder:30B	84.62%	23.28	8.38

Table II: Aggregate performance comparison between *GPT-5.2* and *Qwen3-Coder:30B*.

clearly describe the vulnerability. The efficiency of the agent was evaluated with two key metrics: total execution time and the number of tool invocations, capturing both the speed and intensity of the agent’s interactions.

Local and Cloud Cost Modeling

To assess economic viability, local and LLM deployments were compared using a per-task cost metric, enabling a direct comparison between variable and fixed-cost paradigms.

For cloud-based deployments, costs are treated strictly as operational expenditure (OpEx). The average cost per task ($C_{\text{CloudTask}}$) is calculated by summing the cost (C) of input and output tokens (T) across all N tasks:

$$C_{\text{CloudTask}} = \frac{T_{\text{input}} \times C_{\text{input}} + T_{\text{output}} \times C_{\text{output}}}{N}.$$

Local costs combine OpEx, derived from measured GPU energy consumption (P_{avg}) and electricity rates (P_{kWh}), with amortized CapEx (C_{CapEx}) over the total task volume. The local OpEx is determined by:

$$C_{\text{LocalOpEx}} = \left(\frac{P_{\text{avg}}}{1000} \times t_{\text{hours}} \right) \times P_{\text{kWh}},$$

while the final local per-task cost is the sum of CapEx over N_{tasks} and $C_{\text{LocalOpEx}}$:

$$C_{\text{LocalTask}} = C_{\text{LocalOpEx}} + \frac{C_{\text{CapEx}}}{N_{\text{tasks}}}.$$

This approach enables a fair comparison with cloud-based LLM deployments, which incur no upfront hardware cost but impose variable pricing.

Performance Comparison (R1)

To address R1, cloud and local models were compared in terms of task completion rates, execution time, and tool invocations. Aggregate results in Table II show that Qwen3-Coder:30B achieved an 84.62% pass rate, trailing GPT-5.2 by only 2.56%. Notably, the local model proved significantly more efficient, reducing average execution time by approximately 34% and requiring fewer tool calls.

Table III provides a breakdown of efficacy across difficulty tiers. While both models achieved 100% completion on *easy* tasks, the most significant finding lies in the *hard* category. While the cloud baseline shows a better rate on medium-difficulty tasks, both models achieve identical performance on the hardest challenges. However, *GPT-5.2* tends to produce more detailed and coherent analyses. Difference which is

Model	Difficulty	Total	Passed	Pass Rate
GPT-5.2	Easy	14	14	100.00%
GPT-5.2	Medium	14	13	92.86%
GPT-5.2	Hard	11	7	63.64%
Qwen3-Coder:30B	Easy	14	14	100.00%
Qwen3-Coder:30B	Medium	14	12	85.71%
Qwen3-Coder:30B	Hard	11	7	63.64%

Table III: Task completion results for *GPT-5.2* and *Qwen3-Coder:30B*.

consistent with the significantly larger parameter count and capacity of the cloud model.


Results indicate that *Qwen3-Coder:30B* does not require a significant trade-off in reasoning depth for critical security tasks. Across the evaluated benchmarks, the model achieves performance comparable to the cloud-based baseline (*GPT-5.2*), demonstrating similar capability in multi-step reasoning, vulnerability identification, and structured analysis. These findings suggest that *Qwen3-Coder:30B* can sustain the level of analytical rigor required for security-sensitive workloads while operating under local deployment constraints. Consequently, the results confirm the practical viability of *Qwen3-Coder:30B* as a locally deployed alternative to cloud-hosted models. When integrated within the proposed agentic framework, the model demonstrates performance and reasoning behavior comparable to cloud models, establishing it as a practical substitute for these systems.

Ultimately, these findings confirm the technical viability of Qwen3-Coder:30B as a locally deployed alternative. When integrated within the proposed framework, the model demonstrates performance and reasoning comparable to cloud models at identifying vulnerabilities in Android applications.

Economic Viability Analysis (R2)

To answer R2, we compared the economic viability of both paradigms by estimating a per-task cost. Cloud costs were calculated via usage-based token pricing, while local costs integrated hardware CapEx, specifically 27,000€ for an NVIDIA H100 [13], and OpEx derived from energy consumption at a rate of 0.20€/kWh [12]. While the H100 supports full deployment without resource constraints, we acknowledge that utilizing more cost-effective hardware could further reduce upfront CapEx, though potentially at the expense of higher inference latency or degraded agentic performance.

Our analysis over a 1-million-task workload, illustrated in Figure 3, reveals that cloud-based inference follows a strictly linear cost growth totaling 38,462€, whereas local deployment results in a significantly lower total cost of 27,538€. The cumulative cost curves reveal a break-even point at approximately 700,000 queries, beyond which the local deployment becomes increasingly cost-effective. As the workload scales, the effective cost per query for the local model decreases monotonically as the initial hardware investment is amortized, eventually converging toward its low operational cost floor. Conversely, cloud deployment maintains a constant unit cost and superior cash-flow flexibility for short-term projects. Ultimately, these results demonstrate that while cloud APIs are favorable for low-volume workloads, local deployment provides a substantial economic advantage for sustained, high-volume security analysis.



(a): Bar chart displaying monthly expenditure of 1 million tasks in euros over twelve months.

(b): Cost composition analysis (CapEx vs OpEx) at one million tasks.

Figure 3: Cost comparison between cloud-based and local LLM deployment for 1.0M inference tasks.

V. CONCLUSIONS

This study evaluated the feasibility of deploying local LLMs for Android security analysis using an agentic architecture. Through the integration of domain-specific reverse engineering and semantic analysis tools, locally hosted models are shown to deliver competitive performance while providing improved privacy and control.

Regarding the first research question (R1), the evaluation revealed that the local *Qwen3-Coder:30B* model achieved a task completion rate of 84.62%, closely trailing the performance of *GPT-5.2* with a rate of 87.18%, while simultaneously reducing average execution time. Addressing the second research question, in terms of economic viability (R2), the cost analysis identifies a crossover or threshold point where local deployment becomes financially advantageous. Although cloud-based APIs present a low barrier to entry due to the absence of upfront capital expenditure, their linear cost scaling renders them less efficient for sustained, high-volume analysis. In contrast, the results indicate that a high-end local deployment using an NVIDIA H100 amortizes its initial investment after approximately 700,000 queries.

Overall, this work provides empirical evidence and practical guidance for organizations considering the adoption of local LLM-based agents, supporting the transition of AI-driven security technologies into industrial deployment.

VI. FUTURE WORK

While this work establishes a strong baseline for local agentic security analysis, several promising directions remain for future research. First, the current toolchain is primarily focused on static analysis; future iterations will integrate dynamic analysis capabilities to enable inspection of runtime behavior. Second, the evaluation dataset will be extended beyond CTF-style benchmarks to include real-world Android applications, in order to better reflect practical deployment conditions. Third, future work will explore a broader range of open, agentic-capable local models. In addition, subsequent studies will investigate improved agent coordination

strategies, adaptive tool selection, and memory mechanisms. Finally, incorporating human-in-the-loop feedback mechanisms represents a promising avenue for real-world security workflows.

REFERENCES

- [1] Badhan Chandra Das, M. Hadi Amini, and Yanzhao Wu: "Security and Privacy Challenges of Large Language Models: A Survey" *ACM Comput. Surv.* 57, 6, Article 152 (June 2025), 39 pages.
- [2] Jiawei Liu, Chunqiu Steven Xia, Yuyao Wang, LINGMING ZHANG: "Is Your Code Generated by ChatGPT Really Correct? Rigorous Evaluation of Large Language Models for Code Generation", en *Advances in Neural Information Processing Systems 36 (NeurIPS 2023)*.
- [3] Zhou, Xin and Zhang, Ting and Lo, David: "Large language model for vulnerability detection: Emerging results and future directions" *Proceedings of the 2024 ACM/IEEE 44th International Conference on Software Engineering: New Ideas and Emerging Results*, 2024.
- [4] Priambodo, Tegar Ganang Satrio and Prabowo, Angela Oryza and Puspitarini, Annisa Dwi and Winarso, Raihan Adam Handoyo and Aisyah, Nur and Pratama, Mohammad Yoga and Purwitasari, Diana and Pratomo, Baskoro Adi: "MalQwen: Fine Tuned LLM for Static Android Malware Analysis Report" *IEEE Access*, 2025.
- [5] Walton, Brandon J and Khatun, Mst Eshita and Ghawaly, James M and Ali-Gombe, Aisha: "Exploring Large Language Models for Semantic Analysis and Categorization of Android Malware" *arXiv preprint arXiv:2501.04848*, 2025.
- [6] Lewis, Patrick and Perez, Ethan and Piktus, Aleksandra and Petroni, Fabio and Karpukhin, Vladimir and Goyal, Naman and Küttler, Heinrich and Lewis, Mike and Yih, Wen-tau and Rocktäschel, Tim and others: "Retrieval-augmented generation for knowledge-intensive nlp tasks" *Advances in neural information processing systems*, 2020.
- [7] Wu, Junde and Zhu, Jiayuan and Liu, Yuyuan and Xu, Min and Jin, Yueming: "Agentic reasoning: A streamlined framework for enhancing llm reasoning with agentic tools" *Proceedings of the 63rd Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, 2025.
- [8] Wang, Ziyue and Zhou, Liyi: "Agentic Discovery and Validation of Android App Vulnerabilities" *arXiv preprint arXiv:2508.21579*, 2025.
- [9] Optiv: "InsecureShop: Android Vulnerable CTF Application" *GitHub Repository*. <https://github.com/optiv/InsecureShop>
- [10] Dinesh Shetty: "Android-InsecureBankv2: Insecure Banking Application for Security Testing" *GitHub Repository*. <https://github.com/dineshshetty/Android-InsecureBankv2>
- [11] B3nac: "InjuredAndroid: Vulnerable Android Application for Security Practice" *GitHub Repository*. <https://github.com/B3nac/InjuredAndroid>
- [12] BBVA Research: "Reaping the Benefits of Renewable Energy in the Spanish Economy" *BBVA Research Economic Analysis*, 2025.
- [13] Supermicro: "NVIDIA H100 94GB HBM2" *Smicro.eu Enterprise Solutions Catalog*, 2026.

A Review Of: Zero-Shot Classification of Illicit Dark Web Content with Commercial LLMs: A Comparative Study on Accuracy, Human Consistency, and Inter-Model Agreement

Víctor-Pablo Prado-Sánchez, Adrián Domínguez-Díaz, Luis De-Marcos, José-Javier Martínez-Herráiz
Department of Computer Science, University of Alcalá,
Alcalá de Henares, Spain

victor.prado@uah.es, adrian.dominguez@uah.es, luis.demarcos@uah.es, josej.martinez@uah.es

Abstract- The Dark Web contains a large volume of illicit content that poses major challenges for cybersecurity analysis. Existing classification approaches typically rely on supervised models that require extensive labeled data and frequent retraining. This paper summarizes a recently published study on the use of commercial Large Language Models (LLMs) for zero-shot classification of illicit Dark Web content. Eight proprietary LLMs were evaluated on the CoDA dataset, consisting of 10,000 annotated documents across ten illicit categories. The results show that modern LLMs achieve strong macro-F1 performance without task-specific training, with high agreement with human annotations and substantial inter-model consistency. These findings demonstrate the viability of zero-shot LLMs as scalable tools for forensic analysis and cyber-threat intelligence.

Index Terms- Dark Web, Zero-Shot Learning, Large Language Models, Illicit Content Classification, Cybersecurity

Type of contribution: Already published research [1]

I. INTRODUCTION

The Dark Web is a highly anonymized environment where illicit activities such as drug trafficking, arms trading, hacking services, and financial fraud are widespread [2], [3].

Automated classification of this content is essential for cybersecurity and law-enforcement applications, yet it remains challenging due to the short, noisy, and obfuscated nature of Dark Web texts. Traditional supervised approaches, supported by datasets such as DUTA and DUTA-10K, achieved early success but require extensive labeled data and continuous retraining [2]. The release of the CoDA dataset enabled large-scale, multi-class Dark Web classification and became a standard benchmark in this domain [4]. Transformer-based models, including BERT and DarkBERT, demonstrated strong performance when fine-tuned on CoDA, but their reliance on labeled data limits practical deployment [5], [6], [7]. Recent advances in Large Language Models (LLMs) have introduced zero-shot classification as a viable alternative, with models such as GPT-3.5 and GPT-4 achieving competitive results across multiple domains [8], [9], [10], [11]. However, existing Dark Web studies are typically limited to single-model analyses [7].

This paper summarizes a systematic benchmark of eight commercial LLMs evaluated under identical zero-shot conditions, assessing classification performance, agreement with human annotations, and inter-model consistency to

provide a more realistic evaluation of LLM reliability in sensitive Dark Web cybersecurity scenarios.

II. METHODOLOGY

The study conducts a comparative evaluation of commercial Large Language Models for zero-shot classification of illicit Dark Web content. Experiments are performed on the CoDA dataset, a manually annotated corpus of 10,000 documents covering ten illicit categories [3]. After removing near-duplicate samples using TF-IDF cosine similarity, the final evaluation set comprises 7,970 documents, following established practices in Dark Web text analysis [4].

Eight proprietary LLMs were selected based on availability and relevance for real-world deployment: GPT-3.5 Turbo, GPT-4o, and GPT-4o Mini (OpenAI); Claude 3.5 Haiku (Anthropic); Gemini 2.0 Flash (Google DeepMind); DeepSeek Chat and DeepSeek Reasoner (DeepSeek); and Grok (xAI). All models were accessed through their official APIs using deterministic settings (temperature = 0) to ensure reproducibility, in line with standard LLM benchmarking methodologies [8].

A unified zero-shot prompting strategy was applied to all models. The prompt defined each CoDA category in natural language and required a single JSON-formatted label as output, without in-context examples or fine-tuning, ensuring a strict zero-shot setting consistent with prior work [8], [10].

Performance was evaluated using macro-averaged precision, recall, and F1-score to account for class imbalance [10]. Agreement with human annotations and inter-model consistency were assessed using Cohen's Kappa and Krippendorff's Alpha, with statistical robustness ensured via bootstrap-based confidence intervals [7].

III. RESULTS AND DISCUSSION

The results confirm that all evaluated commercial LLMs perform effectively in zero-shot classification of illicit Dark Web content. As shown in Table I, macro-F1 scores range from 0.83 (GPT-3.5 Turbo) to 0.87 (DeepSeek Chat and Grok), with GPT-4o, GPT-4o Mini, and Gemini 2.0 Flash achieving similarly strong performance around 0.86. This indicates that modern LLMs can reliably perform multi-class Dark Web classification without task-specific training.

Table I
OVERALL PERFORMANCE OF LLMs IN ZERO-SHOT CLASSIFICATION (CODA)

Model	Precision	Recall	Macro F1
GPT-3.5 Turbo	0.84	0.83	0.83
GPT-4o	0.87	0.86	0.86
GPT-4o Mini	0.86	0.86	0.86
Claude 3.5 Haiku	0.86	0.85	0.85
Gemini 2.0 Flash	0.87	0.86	0.86
DeepSeek Reasoner	0.87	0.86	0.86
DeepSeek Chat	0.88	0.87	0.87
Grok	0.87	0.87	0.87

Category-level analysis reveals that classes with clear lexical signals, such as Drugs and Gambling, consistently achieve F1-scores above 0.94, while more semantically ambiguous categories, including Violence and Electronic, remain more challenging across all models. These results reflect the inherent difficulty of distinguishing overlapping illicit activities in short and noisy Dark Web texts.

Beyond accuracy, agreement analysis highlights the reliability of LLM predictions. As summarized in Table II, top-performing models reach Cohen’s Kappa (κ) and Krippendorff’s Alpha (α) values between 0.84 and 0.85, which are comparable to expert-level human agreement. Inter-model consistency is also high, particularly between DeepSeek Chat and Grok, indicating convergence toward similar decision boundaries under standardized zero-shot prompting.

Overall, the combined evidence from Tables I and II suggests that zero-shot LLMs provide not only strong performance but also stable and consistent behavior, supporting their practical use in scalable Dark Web cybersecurity and forensic analysis.

IV. CONCLUSIONS

This extended summary shows that commercial Large Language Models have reached a sufficient level of maturity to support effective zero-shot classification of illicit Dark Web content. Without any task-specific training or fine-tuning, several models achieve competitive performance, high agreement with human annotations, and strong inter-model consistency, confirming their reliability for sensitive classification tasks. These results suggest that modern LLMs can capture relevant semantic patterns in highly noisy and adversarial textual environments such as the Dark Web.

Although supervised models still achieve higher accuracy, their reliance on labeled data and continuous retraining limits practical deployment. In contrast, zero-shot LLMs provide a scalable and cost-effective alternative, enabling rapid adaptation and making them well suited for decision support in cybersecurity and law-enforcement contexts.

Table II
AGREEMENT WITH HUMANS AND INTER-MODEL (TOP MODELS)

Model	κ	α	High Agreement
GPT-4o	0.83	0.83	GPT-4o Mini
Claude 3.5 Haiku	0.83	0.83	GPT-4o
Gemini 2.0 Flash	0.84	0.84	Claude 3.5 Haiku
DeepSeek Chat	0.85	0.85	Grok
Grok	0.85	0.85	DeepSeek Chat

ACKNOWLEDGMENTS

This work has been funded by the Spanish Ministry of Science and Innovation, under the “Project for the analysis and recovery of criminal evidence associated with hidden networks” (PARCHE), with reference PID2021-125645OB-I00 of the 2021 call for “Knowledge Generation Projects”. The presentation of this work at JNIC 2026 has been made possible thanks to the support of the ISDEFE Chair.

REFERENCES

- [1] V.-P. Prado-Sánchez, A. Domínguez-Díaz, L. De-Marcos, and J.-J. Martínez-Herráiz, ‘Zero-Shot Classification of Illicit Dark Web Content with Commercial LLMs: A Comparative Study on Accuracy, Human Consistency, and Inter-Model Agreement’, *Electronics*, vol. 14, no. 20, p. 4101, Jan. 2025, doi: 10.3390/electronics14204101.
- [2] M. W. Al Nabki, E. Fidalgo, E. Alegre, and I. de Paz, ‘Classifying Illegal Activities on Tor Network Based on Web Textual Contents’, in *Proceedings of the 15th Conference of the European Chapter of the Association for Computational Linguistics: Volume 1, Long Papers*, M. Lapata, P. Blunsom, and A. Koller, Eds, Valencia, Spain: Association for Computational Linguistics, Apr. 2017, pp. 35–43. Accessed: Apr. 02, 2025. [Online]. Available: <https://aclanthology.org/E17-1004/>
- [3] G. Avarikioti, R. Brunner, A. Kiayias, R. Wattenhofer, and D. Zindros, ‘Structure and Content of the Visible Darknet’, Nov. 07, 2018, *arXiv: arXiv:1811.01348*. doi: 10.48550/arXiv.1811.01348.
- [4] Y. Jin, E. Jang, Y. Lee, S. Shin, and J.-W. Chung, ‘Shedding New Light on the Language of the Dark Web’, in *Proceedings of the 2022 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, M. Carpuat, M.-C. de Marneffe, and I. V. Meza Ruiz, Eds, Seattle, United States: Association for Computational Linguistics, Jul. 2022, pp. 5621–5637. doi: 10.18653/v1/2022.naacl-main.412.
- [5] Y. Jin, E. Jang, J. Cui, J.-W. Chung, Y. Lee, and S. Shin, ‘DarkBERT: A Language Model for the Dark Side of the Internet’, in *Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, A. Rogers, J. Boyd-Graber, and N. Okazaki, Eds, Toronto, Canada: Association for Computational Linguistics, Jul. 2023, pp. 7515–7533. doi: 10.18653/v1/2023.acl-long.415.
- [6] G. Cascavilla, G. Catolino, and M. Sangiovanni, ‘Illicit Darkweb Classification via Natural-language Processing: Classifying Illicit Content of Webpages based on Textual Information’, presented at the 19th International Conference on Security and Cryptography, Apr. 2025, pp. 620–626. Accessed: Apr. 02, 2025. [Online]. Available: <https://www.scitepress.org/Link.aspx?doi=10.5220/0011298600003283>
- [7] V.-P. Prado-Sánchez, A. Domínguez-Díaz, D. Rodríguez, and J.-J. Martínez, ‘How can ChatGPT help humans in Dark Web content classification? Assessing GPT models reliability and effects of explanations on human decisions’, 2024.
- [8] K. S. Kalyan, ‘A survey of GPT-3 family large language models including ChatGPT and GPT-4’, *Nat. Lang. Process. J.*, vol. 6, p. 100048, Mar. 2024, doi: 10.1016/j.nlp.2023.100048.
- [9] L. Loukas, I. Stogiannidis, P. Malakasiotis, and S. Vassos, ‘Breaking the Bank with ChatGPT: Few-Shot Text Classification for Finance’, in *Proceedings of the Fifth Workshop on Financial Technology and Natural Language Processing and the Second Multimodal AI For Financial Forecasting*, C.-C. Chen, H. Takamura, P. Mathur, R. Sawhney, H.-H. Huang, and H.-H. Chen, Eds, Macao: -, 2023, pp. 74–80. Accessed: Apr. 02, 2025. [Online]. Available: <https://aclanthology.org/2023.finnlp-1.7/>
- [10] Z. Wang, Y. Pang, and Y. Lin, ‘Large Language Models Are Zero-Shot Text Classifiers’, Dec. 02, 2023, *arXiv: arXiv:2312.01044*. doi: 10.48550/arXiv.2312.01044.
- [11] V. P. Prado Sánchez, A. Domínguez Díaz, L. Marcos, and J. J. Martínez Herráiz, *Clasificación zero-shot de contenidos de la Dark Web mediante GPT-3.5: Evaluación de rendimiento y análisis de errores del clasificador*. Universidad de Sevilla. Escuela Técnica Superior de Ingeniería Informática, 2024. Accessed: Apr. 02, 2025. [Online]. Available: <https://hdl.handle.net/11441/160320>

Hacia detectores adaptativos: Transfer Learning en detección de Ataques de Fallos de Tensión

Asier Gamba^{†,§}, Unai Rioja[†], Igor Armendariz[†], Durba Chatterjee[§], Lejla Batina[§]

[†]Equipo de Sistemas Embebidos Ciberseguros, Ikerlan,
Pº JM Arizmendiarieta 2, Arrasate/Mondragon, Basque Country 20500, Spain
{agambra,urioja,iarmendariz}@ikerlan.es

[§]Department of Digital Security, Radboud University,
Houtlaan 4, 6525 XZ Nimega, Países Bajos
{asier.gambra,durba.chatterjee,lejla.batina}@ru.nl

Abstract—La inyección de fallos de tensión (VFI) es un potente ataque físico contra dispositivos electrónicos. Consiste en insertar una perturbación muy breve en la alimentación de un dispositivo para hacerlo tropezar y provocar un comportamiento erróneo que comprometa su seguridad. Típicamente, los sistemas integrados cuentan con un supervisor de tensión que apaga el sistema cuando se detecta un nivel de tensión por debajo de un umbral que garantiza su correcto funcionamiento. Perturbaciones refinadas, inyectadas mediante técnicas modernas, pueden atravesar indetectadas estas defensas y comprometer la ejecución en curso. Recientemente, la inteligencia artificial se ha posicionado como una alternativa prometedora para la detección de estos comportamientos explotables, empleando aprendizaje supervisado para monitorizar la señal de reloj del sistema. Sin embargo, la eficacia de estos detectores se ve severamente limitada al enfrentarse a frecuencias de operación distintas a las utilizadas durante su entrenamiento. Este trabajo estudia la capacidad de generalización de estos modelos entre frecuencias y evalúa la aplicación del aprendizaje por transferencia (transfer learning) para adaptar eficientemente un detector entrenado en una frecuencia a otra. El reto fundamental consiste en lograr la transversalidad del modelo, superando las limitaciones impuestas por las condiciones específicas de su conjunto de entrenamiento.

Index Terms—fault injection, deep learning, countermeasure, transfer learning

I. INTRODUCCIÓN

LOS ATAQUES de inyección de fallos son una técnica de ataque físico en sistemas embebidos que consiste en alterar temporalmente la tensión de alimentación del dispositivo con el objetivo de inducir y explotar malfuncionamientos específicos. Boneh, DeMillo y Lipton demostraron en 1997 que los errores computacionales inducidos durante la ejecución del algoritmo RSA podían exponer la clave privada, en lo que se conoce como el ataque Bellcore [1]. Posteriormente, Biham y Shamir sistematizaron la inyección de fallos aplicada a cifrados simétricos como DES, desarrollando el potente Análisis Diferencial de Fallos (DFA) [2]. A medida que se adoptaron algoritmos más modernos, se confirmó su vulnerabilidad frente a estas técnicas. En particular, Dusart, Letourneux y Vivolo demostraron en 2003 que AES, un estándar mundial de cifrado, también es susceptible a ataques de tipo DFA [3].

En el contexto específico del AES, los fallos inyectados se modelan como modificaciones de la matriz de estado del algoritmo. La gama de métodos de inyección física que se han explorado en la literatura incluye la inyección de fallos mediante perturbaciones en la señal de reloj [4], alteraciones en la tensión de alimentación [5], emisión electromagnética (EMFI) [6] y exposición a radiación láser [7].

II. ANTECEDENTES

La inteligencia artificial ha revolucionado progresivamente la investigación en los campos que pueden sostenerla. Recientemente, la ciberseguridad física de dispositivos criptográficos ha dado los primeros pasos para implementar contramedidas basadas en el aprendizaje supervisado. Este es el caso de la monitorización de la señal de reloj en un dispositivo mientras este ejecuta operaciones criptográficas sensibles. Por ahora, ceñidos a ataques de inyección de faltas de tensión, su premisa es que toda perturbación de tensión que intente provocar un fallo dejará una huella en la señal de reloj, y un modelo entrenado puede detectar con precisión qué tipo de ataques son explotables [8]. Este planteamiento, pendiente de implementación pero con resultados comprobados en la literatura, tiene la ventaja de estar específicamente diseñado para ceñirse a un dispositivo concreto. Sin embargo, los dispositivos pueden funcionar en diferentes frecuencias, lo que implica la necesidad de contar con un modelo de detección afinado a la frecuencia en la que se trabaje. Este paso no es trivial, ya que, según se ha visto, diferentes frecuencias de operación dan lugar a distintos ratios de aparición de fallos y a distintas precisiones de detección de glitches [9].

Este trabajo presenta un análisis experimental de las relaciones entre modelos de CNN entrenados a distintas frecuencias y de su capacidad para apoyarse mutuamente mediante el aprendizaje por transferencia para encontrar modelos generalizables a diferentes frecuencias.

III. CONTEXTO

A. Inyección de Fallos de Tensión

Una evaluación de inyección de fallos de tensión (VFI) consiste en introducir perturbaciones transitorias (glitches) en

la alimentación de tensión de un dispositivo en ejecución para provocar errores como saltar una instrucción, corromper un acceso a la memoria o falsear verificaciones de seguridad. Mediante la inyección controlada de estos glitches, un atacante puede provocar fallos en procesos criptográficos, generando textos cifrados erróneos que pueden ser explotados mediante Análisis Diferencial de Fallos (DFA) [2] para recuperar la clave secreta.

B. Fallos explotables en AES

AES (*Advanced Encryption Standard*) [10] es un algoritmo de cifrado simétrico que, bajo condiciones normales de operación, impide la recuperación de la clave secreta a partir del texto cifrado. Existe un modelo de fallos de AES que describe cómo explotar el cifrado mediante fallos en rondas de transformación específicas. Para el cifrado AES-128, se atacan las transformaciones en las rondas 8 o 9, de modo que luego puedan rastrearse para reconstruir iterativamente la clave completa de 128 bits [11].

C. Aprendizaje Supervisado y Redes Convolucionales

El aprendizaje supervisado (*Supervised Learning*) es un paradigma del aprendizaje automático (*Machine Learning*) en el que un modelo se entrena con un conjunto de datos etiquetados, aprendiendo a mapear entradas a salidas mediante un criterio de optimización. Con un conjunto de entrenamiento adecuado, estos patrones permiten realizar predicciones sobre datos nuevos. Para señales temporales, las arquitecturas más eficaces son las redes neuronales convolucionales (CNN), que aplican operaciones de convolución mediante kernels (filtros) para extraer características locales y capturar dependencias en el tiempo. El tuneado de una red semejante aprende de los datos de entrenamiento y produce predicciones basadas en los patrones despejados. Esto significa que, para datos nuevos que se asemejen a los de entrenamiento, el modelo funcionará bien, pero si la entrada cambia, la precisión se verá afectada.

D. Aprendizaje por transferencia y generalización

Si cambian las condiciones de entrada (por ejemplo, su escala o frecuencia de muestreo), aunque la señal contenga las características relevantes, la precisión del modelo se verá afectada. El aprendizaje por transferencia (transfer learning) es una técnica de aprendizaje automático que permite reutilizar o ajustar (fine-tuning) un modelo previamente entrenado en una tarea para aplicarlo a una tarea relacionada [12]. Para su aplicación, existen diferentes grados de modificación del modelo original: La inferencia directa aplica el modelo tal cual a datos nuevos sin reentrenamiento. La extracción de características congela las capas convolucionales y reentrena únicamente la clasificación. El ajuste fino completo reentrena toda la red.

IV. DATOS DE ENTRENAMIENTO DE FALLOS DE TENSIÓN

Para aplicar el aprendizaje automático al enfoque propuesto, se mide la señal de reloj afectada por glitches caracterizados por tres parámetros: el instante de inyección (timing), la

TABLE I
RESUMEN DE LA EVALUACIÓN DE INYECCIÓN DE FALLOS.

	16MHz	32MHz	50MHz
Ventana del ataque	169us	93us	59us
Frecuencia de muestreo	500MS/s	1GS/s	1GS/s
Puntos de muestreo	1 000	1 000	1 000
Rango de retardos	[1.79, 179]us	[4, 92]us	[2.5, 57.5]us
Paso en retardos	1.79us	4us	2.5us
Rango de duraciones	[4, 108]ns	[8, 180]ns	[8, 180]ns
Paso en duraciones	4ns	4ns	4ns
Rango de tensiones	[0, 1.1]V	[0, 1.2]V	[0, 1.2]V
Paso en tensiones	0.055V	0.06V	0.06V
Medidas totales	56 699	21 243	21 251
Vcap nominal	1.1V	1.2V	1.2V
Respuesta normal	92.02%	91.68%	86.70%
Sin respuesta (reset)	6.28%	3.07%	6.20%
Respuesta con fallos	1.68%	5.19%	7.09%

amplitud y la duración del glitch. Se considera un resultado normal cuando el glitch no produce efecto alguno; un reset si el sistema se apaga; y un fallo si el glitch se propaga durante el proceso de cifrado y altera el cómputo. En contextos criptográficos, puede resultar útil o no para el criptoanálisis, según la naturaleza del error. Para inducir fallos exitosos, es necesario caracterizar previamente la respuesta del sistema ante glitches en distintos parámetros.

La efectividad de la inyección de fallos mediante glitches se evaluó en una placa STM32F410RB NUCLEO. Se retiraron los condensadores de RST, 3V3 y VCAP, como es práctica estándar en las evaluaciones de glitches. Se utiliza la herramienta Riscure Inspector FI junto con el banco de trabajo Spider para la inyección controlada de glitches. Cada glitch se prueba en una ejecución software de AES a diferentes frecuencias: 16, 32 y 50 MHz. Simultáneamente, un osciloscopio captura la señal de reloj, que, junto con el resultado de la encriptación y los parámetros del glitch, completa una medida. En la Tabla I se presenta un resumen de las inyecciones de glitches realizadas.

Como criterio general, se toma la combinación de la duración X y la tensión de cada glitch como potencia de la perturbación. Por tanto, se considerarán potencialmente explotables todos aquellos glitches cuya potencia haya demostrado ser suficiente para provocar fallos. En las evaluaciones, estos valores han sido de $14,96\text{e-}9$ a 16 MHz, $37,44\text{e-}9$ a 32 MHz, y $48,00\text{e-}9$ a 50 MHz.

V. APRENDIZAJE SUPERVISADO PARA ETIQUETAR FALLOS

Los mejores modelos entrenados para cada frecuencia se presentan en la Tabla II, donde cada modelo fue encontrado mediante un GridSearch de 20 iteraciones de 10 épocas. La Tabla III presenta las métricas de clasificación binaria. Las predicciones demuestran una buena generalización del entrenamiento al subconjunto de prueba de cada evaluación. Las predicciones a 16 MHz permiten una mejor caracterización de la potencia de glitch en términos de duración y de tensión. Los conjuntos de 32 y 50 MHz, aunque también generalizan bien, producen un error de predicción algo mayor, con alrededor de 4 % menos de la métrica F1.

TABLE II

RESUMEN DE ARQUITECTURA, DATOS Y ENTRENAMIENTO DE LAS REDES.

	16 MHz	32 MHz	50 MHz
Grid Search	Tamaño entrada	400	400
	Número de bloques conv.	4	3
	Convoluciones por bloque	48,32,128,64	48,96,32
	Tamaño de kernel	5	5
	Número de capas densas	1	1
	Neuronas por capa densa	64	96
	Dropout rate	0.2	0.2
	Learning rate	10^{-3}	10^{-3}
Datos	Clases de salida	2	2
	Nº de trazas	56 699	21 243
	Frec. de muestreo	500 MS/s	1 GS/s
	Muestras / período	31.2	31.25
	Etiquetas normales	37.57 %	46.01 %
Resultado	Etiquetas con fallo	62.43 %	53.99 %
	Accuracy	0.9889	0.9482
	Precision	0.9919	0.9725
	Recall	0.9902	0.9313
	F1-score	0.9911	0.9515

TABLE III

PUNTUACIONES F1 DE TRANSFERENCIA CRUZADA (150 ÉPOCAS).

INF: INFERENCIA DIRECTA. AP: ADAPTACIÓN PARCIAL.

Aplicado a → Modelo de ↓	16 MHz	32 MHz	50 MHz
16 MHz	F1=0,991	Inf: 0,798 AP: 0,937	Inf: 0,637 AP: 0,922
32 MHz	Inf: 0,964 AP: 0,986	F1=0,951	Inf: 0,359 AP: 0,936
50 MHz	Inf: 0,767 AP: 0,989	Inf: 0,637 AP: 0,930	F1=0,944

VI. EVALUACIÓN EXPERIMENTAL DE TRANSFERENCIA ENTRE DOMINIOS DE FRECUENCIA

Cada modelo propuesto se ha entrenado con distintos conjuntos de datos, arquitecturas de red, criterios de clasificación (potencia mínima que produce un fallo) y rangos de parámetros de glitch. La Figura 1 muestra el resultado de la transferencia del modelo de 32 MHz a los datos de 16 MHz. Las gráficas muestran la distribución de los errores de predicción cometidos en tanto por ciento sobre el subconjunto de test y en coordenadas de los parámetros de glitch. Se observa que la diferencia en el criterio de etiquetado original se compensa, a pesar de basarse en potencias mínimas distintas para cada frecuencia. El sistema es capaz de identificar un umbral de estrés equivalente en ambos dominios, lo que sugiere que el modelo ha aprendido a reconocer un patrón en la perturbación independiente de la potencia. Con una adaptación parcial, el modelo mejora considerablemente su exactitud, aunque no alcanza la de la arquitectura entrenada específicamente para el conjunto de 16 MHz. A partir de un modelo entrenado a 50 MHz, la transferencia a 16 MHz logra resultados inferiores.

La Figura 2 presenta los resultados de aplicar un modelo entrenado a 16 MHz (por inferencia directa) al conjunto de datos adquiridos a 32 MHz. Esta transferencia de menos a más frecuencia presenta un desempeño significativamente inferior, a pesar de mantener la misma relación temporal de muestreo. Este comportamiento refuerza la asimetría en la transferencia de aprendizaje entre frecuencias, incluso cuando las formas de onda son similares.




Fig. 1. Distribución de errores de predicción al aplicar transferencia al conjunto de 16 MHz desde modelos preentrenados de 32 y 50 MHz.

Para la transferencia desde 50 MHz, la inferencia directa no logra generalizar para ninguna de las otras dos frecuencias. Este comportamiento refuerza la idea de que la proximidad en frecuencia no basta para garantizar una transferencia exitosa.

A. Transferencia de aprendizaje para 50 MHz

Las transferencias hacia 50 MHz desde frecuencias inferiores presentan la dificultad más marcada. En inferencia directa, ambos modelos colapsan en su clasificación, etiquetando todas las muestras como positivas (clase explotable). Este comportamiento indica una discontinuidad fundamental en la representación de las características al pasar a dominios de mayor frecuencia. En inferencia directa, ambos modelos colapsan y clasifican todas las muestras como positivas (clase explotable). Tras aplicar un ajuste parcial, el rendimiento se recupera notablemente. Esto sugiere que la capa clasificadora debe recalibrarse por completo para alinearse con las condiciones específicas del dominio de 50 MHz.

B. Conclusiones en transferencia

Las conclusiones derivadas del análisis de transferencia de aprendizaje revelan un patrón claro con las propiedades físicas de las señales. Cuando la densidad de muestreo relativa se mantiene, la transferencia es más eficaz, ya que las trazas de onda conservan la misma dimensión. Además, se observa una asimetría sistemática en la dirección de la transferencia. La transferibilidad no es simétrica y su éxito depende de la compatibilidad de la representación temporal y del salto de frecuencia. Esto subraya la importancia de considerar tanto




Fig. 2. Distribución de errores de predicción al aplicar transferencia al conjunto de 32 MHz desde modelos preentrenados de 16 y 50 MHz.




Fig. 3. Errores de predicción del modelo entrenado con los tres conjuntos de datos, representados para cada frecuencia.

la frecuencia nominal como las condiciones de adquisición al diseñar estrategias de transferencia entre dominios temporales.

VII. MODELO MULTIFRECUENCIA

Para evaluar la generalización entre frecuencias, se entrena un modelo para un dataset compuesto por las tres frecuencias (16 MHz, 32 MHz y 50 MHz), manteniendo las condiciones originales de dimensiones, frecuencias de muestreo y umbrales de etiquetado específicas de cada subconjunto. La arquitectura del modelo y sus hiperparámetros se seleccionaron mediante el mismo proceso de grid search empleado para los modelos individuales. La Figura 3 muestra la distribución de los errores del modelo en cada frecuencia. Los errores conservan los patrones identificados en las transferencias individuales. Este comportamiento se corresponde con la asimetría espectral observada anteriormente: un modelo entrenado conjuntamente tiende a sobre-reaccionar en dominios de menor frecuencia y a dejar pasar más fallos en dominios de mayor frecuencia.

A. Conclusiones del modelo multifrecuencia

El enfoque multifrecuencia representa un equilibrio práctico entre rendimiento y generalización, resolviendo la necesidad de desplegar múltiples modelos especializados en distintas frecuencias. No obstante, para aplicaciones críticas, la persistencia de falsos negativos en altas frecuencias sugiere que podría ser beneficioso complementar el modelo con mecanismos explícitos para capturar fallos a alta frecuencia. Una estrategia prometedora para este fin sería una adaptación ligera desde un dominio de muy alta frecuencia, que haya sido entrenada específicamente para reconocer fallos transitorios rápidos.

REFERENCES

- [1] D. Boneh, R. A. DeMillo, and R. J. Lipton, "On the Importance of Checking Cryptographic Protocols for Faults," in *Advances in Cryptology — EUROCRYPT '97*, 1997.
- [2] E. Biham and A. Shamir, "Differential fault analysis of secret key cryptosystems," in *Advances in Cryptology — CRYPTO '97*, 1997.
- [3] P. Dusart, G. Letourneux, and O. Vivolo, "Differential Fault Analysis on A.E.S.," in *Applied Cryptography and Network Security*, 2003.
- [4] M. Agoyan, J.-M. Dutertre, D. Naccache, B. Robisson, and A. Tria, "When Clocks Fail: On Critical Paths and Clock Faults," in *Smart Card Research and Advanced Application*, vol. 6035 of *LNCS*, 2010.
- [5] Y. Lu, "Attacking Hardware AES with DFA," *ArXiv*, vol. abs/1902.08693, 2019.
- [6] A. Dehbaoui, J. M. Dutertre, B. Robisson, and A. Tria, "Electromagnetic Transient Faults Injection on a Hardware and a Software Implementations of AES," in *2012 Workshop on Fault Diagnosis and Tolerance in Cryptography*, 2012.
- [7] B. Colombier, A. Menu, J.-M. Dutertre, P.-A. Moëlllic, J.-B. Rigaud, and J.-L. Danger, "Laser-induced Single-bit Faults in Flash Memory: Instructions Corruption on a 32-bit Microcontroller," in *IEEE International Symposium on Hardware Oriented Security and Trust*, 2019.
- [8] A. Gamba, D. Chatterjee, U. Rioja, I. Armendariz, and L. Batina, "A Neural Network-Based Classifier for Glitch Detection in Clock Traces," in *2025 IEEE International Symposium on Defect and Fault Tolerance in VLSI and Nanotechnology Systems (DFT)*, 2025.
- [9] A. Gamba, U. Rioja, D. Chatterjee, I. Armendariz, and L. Batina, "Machine Learning Fault Injection Detection in Clock Signals: An Analysis of Frequency Impact," in *2025 IEEE Computer Society Annual Symposium on VLSI (ISVLSI)*, 2025.
- [10] National Institute of Standards and Technology, "Advanced Encryption Standard (AES)," Tech. Rep. FIPS PUB 197, U.S. Department of Commerce, 2001.
- [11] T. Chiu and W. Xiong, "SoK: Fault injection attacks on cryptosystems," in *Proceedings of the 12th International Workshop on Hardware and Architectural Support for Security and Privacy*, ACM, 2023.
- [12] J. Gupta, S. Pathak, and G. Kumar, "Deep Learning (CNN) and Transfer Learning: A Review," *Journal of Physics: Conference Series*, 2022.

A Purdue-Aligned Evaluation Framework and Reference Architecture for ICS Cybersecurity Testbeds

Jovan A. Guillén-Mass Roberto Magán-Carrión

Network Engineering & Security Group (NESG)

Research Centre for Information and Communication Technologies (CITIC-UGR)

University of Granada, Granada, Spain.

jaguillenmass@correo.ugr.es, rmagan@ugr.es

Abstract—Industrial Control System (ICS) cybersecurity research depends on testbeds, but their architectural heterogeneity limits comparability and reproducibility. To address this, we propose a Purdue-aligned evaluation framework applied to 27 testbeds to identify recurrent gaps and biases, and derive a cost-efficient, largely virtualizable reference architecture conceived as a modular baseline for reproducible and extensible ICS cybersecurity experimentation.

Index Terms—Cybersecurity, Industrial Control Systems (ICS), Information Technology(IT), Operational Technology (OT), Testbeds.

Contribution type: *Ongoing investigation*

I. INTRODUCTION

Given the threat landscape reported in the **2025 SANS state of ICS/OT cybersecurity report**, there is a clear need to develop and validate cybersecurity mechanisms tailored to OT environments, where a lack of controls remain prevalent [1]. As experimentation in operational ICS is unsafe, research relies on testbeds. However, their architectural variability hampers systematic comparison under increasing virtualization and Machine learning adoption. This motivates a unified, Purdue-aligned framework to analyze existing testbeds and guide the design of reproducible simulation-based platforms aligned with industrial security practices like IEC 62443-3-3 [2].

II. BACKGROUND

This section introduces the core concepts underpinning the proposed framework.

A. The Purdue Enterprise Reference Architecture

The Purdue Model [3] is the standard hierarchical reference for structuring ICS architectures, spanning from field level processes to enterprise systems, enabling consistent analysis of segmentation, interoperability, and architectural completeness. It defines the *Physical Process* (Level 0) with sensors and actuators, *Basic Control* (Level 1) implemented by Programmable Logic Controllers (PLCs), *Supervisory Control* (Level 2) comprising Human–Machine Interfaces (HMIs), Supervisory Control and Data Acquisition (SCADA), and historians, *Site Operations*

(Level 3) including engineering workstations (EWS), the *Industrial DMZ* (Level 3.5) enforced through firewalls (FWs), and *Enterprise Services* (Level 4) such as Enterprise Resource Planning (ERP) platforms supporting business functions [4], [5].

B. ICS Testbeds: Definition, Purpose, and Their Relationship with IT and OT

An ICS testbed is a controlled environment used to emulate industrial systems for cybersecurity experimentation without impacting real operations [5]. Testbeds may be *physical*, offering high fidelity at high cost; *virtualized*, enabling scalable and automated experimentation with reduced realism; or *hybrid*, combining both to balance realism and flexibility.

III. METHODOLOGY

This section defines the methodology for evaluating ICS testbeds by formalizing functional maturity and architectural coverage:

A. Functionality Measure (FM) calculation

Derived from our previous quantitative framework [5], which assesses a testbed’s suitability for research-oriented experimentation. FM is computed from six criteria: **scalability**, **integration capability**, **flexibility**, **automation capability**, **attack simulation capability**, and **dataset generation capability**. Each testbed is scored as High, Medium, or Low (3, 2, or 1) and obtained as the arithmetic mean of the six criteria:

$$FM = \frac{1}{6} \sum_{i=1}^6 f_i,$$

where f_i denotes the numerical score for criterion i .

The previously reported FM values from [5] are reused. Lastly, testbeds are categorized into Physical, virtualized and Hybrid.

B. Architectural Completeness (AC) calculation

AC is computed by identifying canonical assets mapped to Purdue levels (0 to 4 and 3.5) II together with research-oriented components required for realistic cybersecurity experimentation, including security, monitoring, identity, trust, and adversarial capabilities. Specifically, AC accounts for the presence of network infrastructure (net) enabling component communication [6], segmentation Through firewalls (Fw), administrative access via bastion (B) hosts, centralized logging and correlation through SIEM platforms [5], dedicated attack-simulation (AS) environments, dataset generation [5], and enterprise-grade identity and trust services such as Active Directory (AD) and Certificate Authorities (CA). Each asset is treated as a binary feature (present = 1, absent = 0), and calculated as:

$$AC = \frac{\text{Implemented}}{\text{Total}} \times 100$$

C. Computation of Dimensions of a comprehensive Testbed (DcT)

The DcT represents the joint analysis of (*FM*) and (*AC*) by projecting testbeds onto a two-dimensional plane (Figure 1). This quadrant defines four profiles: **Minimal/Prototype** (low FM/AC), **Broad** (high AC, low FM), **Specialized** (high FM, moderate AC), and **Reference** testbeds, which maximize both dimensions.

IV. FINDINGS

This section summarizes key findings from the evaluation, highlighting recurring trends and design patterns relevant to reference architecture.

A. Results

Table I shows strong heterogeneity in how recent ICS testbeds implement Purdue-layer components. Most emphasize software-based or containerized PLCs with lightweight supervision, as in Longo et al. [7], Giehl et al. [8], Minseo et al. [9], and Machaka et al. [10], [11], typically combined with Matlab process emulation, whereas fully physical controllers are rare [12]. HMIs and SCADA appear sporadically, mainly FUXA and ScadaBR/Scada-LTS [7], [8], [13], [9], [10].

Upper layer and cross-cutting components remain largely absent and attacker environments appear only in a few works [14], [15], [7], [8], [16], while EWS, ERP/MES, bastions, and historians are seldom reported. Protocol support is similarly narrow, dominated by Modbus/TCP [13], [9], [10], with limited adoption of OPC UA [8]. These trends are reflected in AC scores, with most testbeds below 40% [17], [18], [19], [20], [21], [22], [23], [7] and only a few exceeding 50% [14], [15], [12], indicating predominantly narrow architectural scope.

Figure 1 maps testbeds on the AC–FM plane, showing most clustered as *Specialized* (high FM, low AC), few as *Reference*, and marginal presence of

Architecturally broad and *Minimal/Prototype* designs, revealing a persistent FM–AC trade-off that motivates the proposed architecture.

Across indicators, OpenPLC dominates PLC implementations (12/27), while physical PLCs/IEDs remain rare (4/27). Supervisory support is limited and fragmented: ScadaBR leads SCADA adoption (5/27), followed by FUXA and Scada-LTS (3/27 each), with nearly half of the testbeds omitting SCADA entirely (13/27) and most lacking HMIs (18/27). Engineering and enterprise components (EWS, MES, ERP, jump servers) are absent across all studies. Networking is predominantly container-based (16/27), often combined with GNS3 (6/27) or Mininet (5/27), whereas physical devices are uncommon (3/27). Historian support is sparse (9/27), mainly via InfluxDB (4/27) or Elasticsearch (3/27); security instrumentation is similarly limited, with firewalls/IDS in 7/27 and SIEM in only 3/27. Attacker environments appear in 10/27 testbeds, typically using Kali Linux (7/27). Protocol coverage is strongly skewed toward Modbus/TCP (15/27), with limited DNP3 support (5/27) and only marginal adoption of other industrial protocols.

Accordingly, the proposed architecture (Figure 2) integrates a Simulink-based process model and Open-PLC (Levels 0–1), supervisory and telemetry services (FUXA, ScadaBR, EWS, InfluxDB/Telegraf) at Level 2, identity and trust services (Samba4 AD, Smallstep CA) at Level 3, an iDMZ with pfSense and an OpenSSH bastion (Level 3.5), and enterprise-level analytics and adversarial capabilities (Elastic+MinIO, Odoo, Kali) at Level 4 [34]. Secure communication will be based on OPC UA and with Modbus/TCP retained for legacy comparison, deployed over a hybrid GNS3–Docker fabric with Open vSwitch and VyOS to enforce zoning and enable reproducible traffic capture.

V. CONCLUSIONS

Our framework jointly analyzes (*FM*) and (*AC*), showing that surveyed testbeds rarely maximize both dimensions simultaneously (e.g., high FM in [29], high AC in [14], [15], and more balanced designs in [16], [13], [10]). To address this imbalance, we propose a Purdue-aligned reference architecture (Figure 2) integrating virtualized control, supervisory, enterprise, and security layers, where automation and containerization enhance FM and explicit upper-layer services increase AC. Future work will focus on implementing this architecture in alignment with IEC 62443-3-3 and generating contextually complete datasets for advanced ICS/OT analysis.

ACKNOWLEDGMENTS

This publication has been mainly funded by MICIN/AEI/10.13039/501100011033 under grants PID2024-161902OB-I00 and by the project NetSEA-GPT (C-ING-300-UGR23) funded by Consejería de Universidad, Investigación e Innovación and

					Purdue levels												
Class	Paper	Year	FM [5]	AC(%)	0	1	2			3			3.5		4		
					P	PLC	HMI	SCADA	His	EWS	AD	CA	B	Fw	ERP	SIEM	AS
Virtualized	Brown et al. [17]	2025	2.5	21.43	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
	Sweeten et al. [24]	2025	1.83	42.86	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
	Lo et al. [18]	2025	2.33	21.43	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
	Martinez et al. [14]	2025	2.33	57.14	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
	Gaffurini et al. [19]	2025	1.33	14.29	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
	Keller et al. [21]	2025	2.33	28.57	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
	Chandra et al. [22]	2025	2.33	35.71	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
	Sande et al. [23]	2025	2.67	28.57	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
	Machaka et al. [11]	2025	2.5	35.71	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
	Oliveira et al. [25]	2025	1.33	21.43	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
	Salazar et al. [16]	2024	2.75	42.86	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
	Veeramachaneni et al. [26]	2024	1.66	7.14	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
	Longo et al. [7]	2024	2.66	35.71	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
	Zhu et al. [13]	2024	2.66	42.86	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
	Giehl et al. [8]	2024	2.66	42.86	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
	Murillo et al. [27]	2024	2.58	21.43	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
	Dehlaghi-Ghadim et al. [28]	2024	2.75	35.71	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
	Hybrid	Machaka et al. [10]	2024	2	42.86	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
Longo et al. [29]		2023	2.91	35.71	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
Qin et al. [30]		2023	2.58	21.43	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
Minseo et al. [9]		2023	2.58	42.86	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
Norton et al. [20]		2025	2.08	28.57	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
Mustafa et al. [15]		2025	2.41	57.14	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
Lucchese et al. [31]		2024	2.41	21.43	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
Mengmeng et al. [32]		2021	2	14.29	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
Physical	Seongmin et al. [33]	2025	1.33	28.57	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
	Katuri et al. [12]	2024	2	50.00	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
✓ Presence / Explicit implementation																	
✗ No data / Not declared																	

✓ Presence / Explicit implementation
 ✗ No data / Not declared

Table I
 TECHNOLOGY COMPONENTS COVERAGE ACROSS REVIEWED ICS TESTBEDS.




Figure 1. Magic Quadrant of ICS testbeds

the European Union through the ERDF Andalusia Program 2021-2027.

REFERENCES

- [1] J. D. Christopher, "State of ics/ot security 2025," November 2025, sANS State of ICS/OT Security Survey.
- [2] International Society of Automation (ISA), "Isa/iec 62443 series of standards," <https://www.isa.org/standards-and-publications/isa-standards/isa-iec-62443-series-of-standards>, 2024, accessed: 2026-02-19.
- [3] T. J. Williams, "The purdue enterprise reference architecture," *Computers in Industry*, vol. 24, no. 2, pp. 141–158, 1994. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/0166361594900175>
- [4] M. Conti, D. Donadel, and F. Turrin, "A Survey on Industrial Control System Testbeds and Datasets for Security Research," *IEEE Communications Surveys and Tutorials*, 2021.
- [5] J. A. Guillén Mass, R. A. Rodríguez Gómez, and R. Magán Carrión, "From theory to practice: assessing the suitability of testbeds in industrial cybersecurity," in *Actas de las X Jornadas Nacionales de Investigación en Ciberseguridad*. Zaragoza: Universidad de Zaragoza, 2025, pp. 198–205.




Figure 2. Testbed design proposal.

- [6] IEC, "IEC/TS 62443-1-1," 2009.
- [7] G. Longo, F. Lupia, A. Merlo, F. PAgano, and E. Russo, "A data anonymization methodology for security operations centers: Balancing data protection and security in industrial systems," *Information Sciences*, 2024.
- [8] A. Giehl, M. P. Heintz, and V. Embacher, "EmuFlex: A Flexible OT Testbed for Security Experiments with OPC UA," *Association for Computing Machinery*, 2024.
- [9] K. Minseo, J. Seungho, J. Cho, and G. Seonghyeon, "Data-Driven ICS Network Simulation for Synthetic Data Generation," *Electronic*, 2023.
- [10] V. Machaka, S. Figueroa-Lorenzo, S. Arrizabalaga, and J. Hernantes, "Comparative analysis of the standalone and hybrid sdn solutions for early detection of network channel attacks in industrial control systems: A wwp case study," *Internet of Things*, vol. 28, p. 101413, 2024. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S2542660524003548>
- [11] V. Machaka, S. Figueroa-Lorenzo, S. Arrizabalaga, B. Elduayen-Echave, and J. Hernantes, "Assessing the impact of modbus/tcp protocol attacks on critical infrastructure: Wwp case study," *Computers and Electrical Engineering*, vol. 126, p. 110485, 2025. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0045790625004288>
- [12] K. Katuri, S.-Y. Park, F. Miao, and J. Zhao, "Demonstration of DoS Attacks on Modbus Protocol Using an Experimental CPS Testbed," *North American Power Symposium (NAPS)*, 2024.
- [13] y. Zhu, "A Sandbox for Industrial Control Systems (security)," *Université catholique de Louvain*, 2024.
- [14] A. Martínez and A. Martínez, "Diseño de una infraestructura de red OT industrial con requisitos de ciberseguridad." Ph.D. dissertation, Universidad politécnica de Cartagena, Catagena, Jun. 2025. [Online]. Available: <https://repositorio.upct.es/server/api/core/bitstreams/65f45fe2-4120-42ca-bbde-66a62591827e/content>
- [15] M. Mustafa, N. Patari, S. Basumallik, and A. Srivastava, "Augmenting Decision-Making of Human-in-the-loop Operators for Resilient Cyber-Power Systems," *Institute of Electrical and Electronics Engineers (IEEE)*, 2025.
- [16] L. Salazar, E. Lopez-Morales, J. Lozano, C. Rubio-Medrano, and A. Cárdenas, "ICSNet: A Hybrid-Interaction Honeynet for Industrial Control Systems," *Association for Computing Machinery*, 2024.
- [17] J. Brown, D.-S. Pham, S.-T. Soh, F. Motalebi, S. Eswaran, and M. Almashor, "Ics-simlab: A containerized approach for simulating industrial control systems for cyber security research," in *2025 IEEE Conference on Communications and Network Security (CNS)*, 2025, pp. 1–6.
- [18] C. Lo, J. Christie, T. Y. Win, Z. Rezaeifar, Z. Khan, and P. Legg, "Trist: Towards a container-based ics testbed for cyber threat simulation and anomaly detection," in *Proceedings of the International Conference on Cybersecurity, Situational Awareness and Social Media*, M. G. Jaatun, C. Onwubiko, P. Rosati, A. Rege, H. Hindy, A. Erola, and X. Bellekens, Eds. Singapore: Springer Nature Singapore, 2025, pp. 225–239.
- [19] M. Gaffurini, D. Brandão, S. Rinaldi, A. Flammini, E. Sisinni, and P. Ferrari, "Characterizing the real-time communication performance of virtual plc in industrial edge platform," *IEEE Open Journal of Instrumentation and Measurement*, vol. 4, pp. 1–11, 2025.
- [20] G. Norton, J. Landsborough, E. Orozco, and J. Fields, "Containerized Cozenage: Exploring the Effectiveness of High Interaction ICS Honeypot Containers," *Hawaii International Conference on System Sciences (HICSS)*, 2025.
- [21] H. Keller, S. Aboelmagd, S. S. Refaat, A. Takiddin, M. Ismail, and E. Serpedin, "Multi-task graph-based attack detection and localization in cyber-physical power systems," *2025 33rd European Signal Processing Conference (EUSIPCO)*, pp. 1752–1756, 2025. [Online]. Available: <https://api.semanticscholar.org/CorpusID:283098985>
- [22] S. C. Das and T. Vu, "Scalable cyber-physical testbed for cybersecurity evaluation of synchrophasors in power systems," 2022. [Online]. Available: <https://arxiv.org/abs/2207.12610>
- [23] J. Sande, F. Wu Zhuo, M. Alonso, and S. Pastrana, "Espgrid: Emulation-simulation for power smart grids," *SoftwareX*, vol. 31, p. 102307, 2025. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S2352711025002730>
- [24] J. Sweeten, A. Elshazly, A. Takiddin, M. Ismail, S. S. Refaat, and R. Atat, "Cyber-physical fusion for gnn-based attack detection in smart power grids," *IEEE Open Access Journal of Power and Energy*, vol. 12, pp. 515–528, 2025.
- [25] L. Oliveira and E. Gurjão, "Analisador automático de segurança cibernética para o setor elétrico," in *Anais Estendidos do XXV Simpósio Brasileiro de Cibersegurança*. Porto Alegre, RS, Brasil: SBC, 2025, pp. 293–298. [Online]. Available: https://sol.sbc.org.br/index.php/sbseg_estendido/article/view/36767
- [26] V. Veeramachaneni, "Emerging Authentication Technologies for Zero Trust in IoT Systems," *Journal of Advance Research in Mobile Computing*, 2024.
- [27] A. Murillo, R. Taormina, N. Tippenhauer, and S. Galelli, "A Thorough Cybersecurity Dataset for Intrusion Detection in Smart Water Networks," *International Join Conference on Water Distribution System Analysis (WDSA) Computing and Control in the Water Industry (CCWI)*, 2024.
- [28] A. Dehlaghi-Ghadim, N. Ericsson, L.-G. Magnusson, M. Eriksson, M. Helali Moghadam, A. Balador, and H. Hansson, "Using Decision Support to Fortify Industrial Control System against Cyberattacks," *International Conference on Emerging Technologies and Factory Automation (ETFA)*, 2024.
- [29] G. Longo, A. Orlich, S. Musante, A. Merlo, and E. Russo, "MaCySTe: A virtual testbed for maritime cybersecurity," *SoftwareX*, 2023.
- [30] X. Qin, F. Jiang, C. Dong, and R. Doss, "A hybrid cyber defense framework for reconnaissance attack in industrial control systems," *Computers and Security*, 2023.
- [31] M. Lucchese, G. Salerno, and A. Pugliese, "A Digital Twin-Based Approach for Detecting Cyber-Physical Attacks in ICS Using Knowledge Discovery," *Applied Sciences*, 2024.
- [32] G. Mengmeng, C. Jin-Hee, K. Dongseong, D. Gaurav, and C. Ing-Ray, "Proactive Defense for Internet-of-things: Moving Target Defense With Cyberdeception," *Arxiv*, 2020.
- [33] L. Seongmin, N. Yonghun, C. Juwon, J. Guckhyeon, I. Jeong-min, J. Sanghyun, F. Abdulaziz Alfouzan, and K. Kim, "Securing Maritime Autonomous Surface Ships: Cyber Threat Scenarios and Testbed Validation," *Institute of Electrical and Electronics Engineers (IEEE)*, 2025.
- [34] J. S. Irazustabarrena and K. L. Iturbe, "Design and control of flexible and distributed production systems using digital twins," Bachelor's thesis, School of Engineering Science, University of Skövde, 2023, independent thesis Basic level (degree of Bachelor), 20 credits / 30 HE credits. [Online]. Available: <https://www.diva-portal.org/smash/record.jsf?pid=diva2:1782768>

Prediction of hourly cyber support helpline request volume for real-time alerting systems

Lluís Bermúdez
Dept. Mathematics,
RiskCenter-IREA, Universitat
de Barcelona
Av. Diagonal, 690, 08034
lbermudez@ub.edu

Montserrat Guillen
Dept. Econometrics,
RiskCenter-IREA, Universitat
de Barcelona
Av. Diagonal, 690, 08034
mguillen@ub.edu

Pau Nerín
Dept. Econometrics,
RiskCenter-IREA, Universitat
de Barcelona
Av. Diagonal, 690, 08034
paunerin@gmail.com

Abstract- We build a predictive model to forecast the hourly volume of calls to the national cybersecurity helpline in Spain. We explore various modelling strategies, comparing Generalized Linear Models (GLM) versus Machine Learning algorithms, validated through a Walk-Forward Rolling Window methodology to take into account the time structure of the data. We propose the design of a real-time alert system based on the final weighted XGBoost model. The system anticipates significant increases in demand, allowing the hotline managers to increase the number of operators to prevent service collapse. This work presents a research project developed jointly with the National Cybersecurity Institute of Spain (INCIBE).

Index Terms- Machine Learning, cybersecurity, operational efficiency, generalized linear models, Walk-Forward.

Type of contribution: *Original Research.*

I. INTRODUCTION

In recent years, the widespread use of new technologies has led to a significant increase in exposure to cyber threats. To address this growing concern, INCIBE provides the 017 helpline, a free service offering advice and technical support to citizens and companies.

The rising trend in cybersecurity incidents poses a direct operational risk: the potential saturation of the 017 service. An unexpected surge in call volume can compromise the quality of the service, preventing users from receiving immediate assistance. Therefore, effective risk management requires developing tools capable of anticipating demand peaks to optimize resource allocation and avoid service overload.

To address this challenge, this study pursues two main objectives. Firstly, it aims to conduct a rigorous data analysis to develop a predictive model capable of estimating the hourly volume of calls to the 017 service. Secondly, based on the optimal model, the study proposes the design and implementation of a Real-Time Alert System. This interactive tool would allow for continuous monitoring of demand and provides early warnings of potential saturation, ensuring the operational efficiency and reliability of the service.

II. DATA

The data used in this study corresponds to the anonymized call

logs of the 017 service, provided by INCIBE under strict confidentiality agreements.

The original dataset contained records from 2023 and 2024, with a total of 250,665 observations, where each row represents an individual call. To align the data with the predictive objective, a cleaning process was carried out. Initially, the dataset included various call types, such as dropped calls or surveys. We filtered the data to keep only "answered calls", as these reflect the actual demand managed by operators and the workload of the service.

Subsequently, the data was transformed from individual records into a time series structure using SQL language, aggregating the number of calls by hour. The final dataset consists of 10,980 hourly observations. To capture temporal patterns, we generated several explanatory variables through feature engineering. These include calendar variables such as the hour, day of the week, month, year, and a binary variable for national holidays (*holiday*). Additionally, autoregressive variables were created to account for the series' inertia, specifically lags for the previous hour (*hour1*), two hours prior (*hour2*), the same hour on the previous day (*day1*), and the same hour in the previous week (*week1*).

In conclusion, the final dataset used for the analysis and modelling process consists of 10,980 observations and 11 variables, which are detailed in Table I. The distribution of the target variable, *tot_calls*, is displayed in Fig. 1. As observed, the data shows a marked positive skewness and a high concentration of values near zero, which is characteristic of count data.




Fig. 1: Histogram of the total hourly number of calls handled

TABLE I: DESCRIPTION OF THE VARIABLES IN THE FINAL DATABASE

Variable	Type	Description
tot_calls	Numeric	Hourly calls handled by 017
hour	Categorical	Hour of the day when the call is handled
weekday	Categorical	Day of the week when the call is handled (Monday/.../Sunday)
year	Categorical	Year when the call is handled (2023/2024)
month	Categorical	Month when the call is handled (January/.../December)
holiday	Categorical	Dummy variable (1 = national holiday, 0 = otherwise)
hour1	Numeric	Number of calls handled in the previous hour
hour2	Numeric	Number of calls handled two hours earlier
day1	Numeric	Number of calls handled on the previous day
week1	Numeric	Number of calls handled in the previous week

III. METHODOLOGY

This section includes three steps to analyse the time series of counts and to predict the volume of calls handled by INCIBE. To ensure the model's viability in a real-world scenario, the methodology strictly respects the temporal structure of the data.

A. Simulation and Temporal Validation Algorithm

Since the objective is to build a real-time alert system, standard cross-validation methods are unsuitable as they might use future data to predict past events. Instead, we implemented a Walk-Forward Rolling Window algorithm [1].

This methodology acts as a sliding window: the model is trained on a fixed set of past observations (training window) to predict the immediate next hour. Then, the window moves one step forward, discarding the oldest observation and including the newest one, and the model is retrained. This process is repeated for the entire dataset, ensuring that predictions are always generated using the most recent information available without violating temporal causality [2].

This specific approach is fundamental for the development of the Real-Time Alert System, as it requires a dynamic model capable of constant retraining. By continuously updating the training set, the system can effectively capture potential

structural changes and shifts in call volume trends, ensuring high adaptability to evolving scenarios.

B. Applied models

In all the approaches evaluated, the response variable is defined as the total number of calls handled by the 017 service per hour (*tot_calls*). The vector of explanatory variables, common to all models, includes calendar features (hour, day of the week, month, national holiday) and the autoregressive lags described in the Data section (*hour1*, *hour2*, *day1*, *week1*). Additionally, quadratic and cubic terms for the *hour* variable were included in the linear models to capture daily cycles.

We adopted a two-stage modelling strategy to identify the optimal approach. Initially, Generalized Linear Models (GLM) were applied as a baseline, specifically Poisson Regression, which is the standard approach for modelling count data. However, given that the variance of the data significantly exceeds the mean—indicating overdispersion—we also implemented a Negative Binomial Regression.

To overcome the limitations of parametric approaches, we subsequently explored Machine Learning algorithms, specifically Regression Trees and XGBoost [3]. The justification for introducing these techniques in this context is twofold. First, their non-parametric flexibility supports the development of a robust Real-Time Alert System, as they avoid restrictive distributional assumptions and can better adapt to evolving call patterns driven by emerging cyber threats or campaigns. Second, these models naturally handle non-linearity, unlike GLMs that require manual specification of functional forms (such as polynomial terms), since methods like XGBoost automatically capture complex non-linear relationships and higher-order interactions between variables, including effects like the interplay between holidays and specific times of day.

C. Evaluation and Comparison Criteria

To rigorously evaluate the predictive performance within the Walk-Forward framework, we employed both standard accuracy metrics and specific stability indicators relevant to the alert system's operational goals.

We assessed the magnitude of errors using the Root Mean Square Error (RMSE) and the Mean Absolute Error (MAE). RMSE penalizes larger deviations more heavily, while MAE provides a linear interpretation of the average error.

To evaluate the model's ability to capture the variability of the data, we employed the Explained Variance Score (EVS). In parallel, the Coefficient of Determination was used to quantify the goodness of fit relative to a baseline model. Within the Walk-Forward validation framework, R^2 was not treated as a single static metric but was iteratively computed across sliding windows to assess its temporal stability.

Finally, to align the technical evaluation with INCIBE's operational goals, we defined a custom Overestimation Ratio to quantify the aggregate bias. Specifically, values greater than

1 indicate overestimation, while values less than 1 indicate underestimation. A higher ratio indicates a more conservative model in its predictions, better anticipating potential system collapses and enabling INCIBE to adopt a more proactive stance. For INCIBE, this represents a risk-aversion strategy: it is deemed preferable to have a surplus of 017 operators (an efficiency cost) than a shortage (a service failure). In this way, the objective of ensuring high-quality and immediate service in the face of a potential increase in cyberattacks is addressed.

IV. RESULTS

This section compares the evaluated models and proposes a Real-Time Alert System. First, we evaluate the performance of Generalized Linear Models (GLM) and Machine Learning algorithms across different time windows. Subsequently, we identify the optimal model configuration and validate the operational strategy, concluding with the presentation of the proposed Real-Time Alert System.

A. Model Comparison and Window Selection

To determine the optimal configuration, we evaluated four models (Poisson, Negative Binomial, Regression Tree, and XGBoost) using three different sliding window sizes (3000, 5000 and 7000 observations). Table II summarizes the performance metrics averaged across the rolling window iterations.

TABLE II: MODEL PERFORMANCE METRICS BY TRAINING WINDOW SIZE

	Model	RMSE	MAE	EVS	$\overline{R^2}$	Ratio
3000 observations	Poisson	4.49	3.43	0.63	0.62	1.17
	Negative Binomial	4.51	3.44	0.63	0.62	1.16
	Regression Tree	4.89	3.76	0.56	0.56	1.19
	XGBoost	4.75	3.63	0.59	0.94	1.12
5000 observations	Poisson	4.55	3.46	0.62	0.64	1.16
	Negative Binomial	4.57	3.47	0.62	0.64	1.16
	Regression Tree	4.97	3.82	0.55	0.57	1.21
	XGBoost	4.66	3.53	0.60	0.90	1.11
7000 observations	Poisson	4.56	3.43	0.60	0.63	0.96
	Negative Binomial	4.57	3.44	0.61	0.63	0.97
	Regression Tree	4.90	3.74	0.54	0.54	1
	XGBoost	4.61	3.46	0.59	0.87	1.01

As observed in Table II, the selection of the window size involves a trade-off between metric precision and temporal stability. The 7000-observation window was discarded because it exhibited a decreasing trend in the coefficient of determination (R^2) and a Ratio close to or below 1. This fails to meet the operational requirement of the Alert System, which

requires a conservative approach (overestimation) to ensure resource availability during demand spikes.

Conversely, the 3000-observation window demonstrates an increasing trend in the R^2 , confirming that the model stabilizes and improves its explanatory power as it processes recent information. While increasing the window to 5000 observations yields a marginal improvement in accuracy (reducing MAE and RMSE by less than 0.15 units), it does not justify the loss of adaptability to structural changes. Therefore, the 3000-observation window is selected as the optimal equilibrium.

Once the window size was fixed, we compared the candidate models. Generalized Linear Models (Poisson and Negative Binomial) showed excellent accuracy metrics (RMSE and MAE). However, the primary objective of this study is not merely valid inference, but the development of a robust Real-Time Alert System capable of operating in a volatile environment.

In this context, parametric models present a critical weakness: they impose rigid distributional assumptions (e.g., assuming calls always follow a Poisson distribution). Given the nature of cybersecurity, where a massive attack or a new awareness campaign can drastically alter the data structure overnight, a parametric model might fail to adapt.

XGBoost, as a Machine Learning algorithm, does not make these strict assumptions about the underlying data distribution. This non-parametric flexibility allows it to capture complex, non-linear patterns that GLMs miss. This is evidenced by the Coefficient of Determination (R^2), as illustrated in Fig. 2. While GLMs fluctuate, XGBoost maintains a high and stable R^2 (avg. 0.94) over time.




Fig. 2: Evolution of the R^2 for each model trained on a 3000-observation rolling window.

Finally, to ensure that choosing XGBoost to gain stability did not result in a significant loss of accuracy, we performed a Mann-Whitney-Wilcoxon test comparing the absolute errors of the Negative Binomial model versus XGBoost. The result ($p\text{-value} > 0.05$) confirmed that the difference in errors is not statistically significant. Consequently, XGBoost is the superior choice: it matches the accuracy of parametric models while providing the adaptability and overestimation capacity (Ratio > 1) required for an effective alert system.

To visually validate this conclusion, Fig. 3 compares the predictions of both models against the observed data. As

shown, while the Negative Binomial model tends to smooth out the series, the XGBoost model demonstrates superior sensitivity to high-frequency variability, effectively capturing sudden demand spikes. This responsiveness is critical for an operational alert system, where detecting potential saturation is prioritized over minimizing average error during low-activity periods.




Fig. 3: Real handled calls (red) vs. predicted (yellow) for the Negative Binomial and XGBoost models.

B. Proposal of Real-Time Alert System

To translate the model's predictive capabilities into an operational tool for INCIBE, we propose the implementation of an alert system based on the definitive XGBoost model. The validation of this model was structured under a rigorous Walk-Forward scheme using a training window of 3,000 observations, ensuring that predictions reflect the time series' most recent dynamics without sacrificing historical robustness.

Crucially for its potential deployment, it was verified that updating the model on a nightly basis offers the same precision as hourly retraining. This finding suggests the system would be operationally viable for INCIBE, as it would eliminate the inefficiency of constant hourly processing and optimize computational resources without compromising reliability.

Built upon this methodological foundation, the proposed operational workflow would function on a daily cycle. Once the model completed its nightly retraining, the system would automatically generate a complete set of hourly predictions for the entire subsequent day. To ensure maximum accuracy, the interface would be designed to automatically detect the date, requiring only a simple validation—or manual toggle—to indicate if the following day is a National Holiday.

This predictive output would then be screened against a rigorous safety threshold to proactively detect saturation risks. This threshold would be dynamically defined using the full historical dataset: calculated as the historical mean plus one standard deviation, segmented by day of the week and specific hour. If the predicted call volume for any specific hour were to exceed this calculated upper bound, the system would trigger a distinct alert message. This would allow the tool to pinpoint exact moments of risk, signalling to operators and managers when they should exercise heightened vigilance.

From a management perspective, this tool would offer more than just a numerical estimate; it would function as a risk management instrument. Its implementation would enable service managers to anticipate demand peaks and make preventive strategic decisions—such as reinforcing staffing levels during those specific flagged hours—ensuring that

INCIBE's quality and service standards remain uncompromised in the face of workload fluctuations.

V. CONCLUSIONS AND FUTURE WORK

This study successfully developed and validated a dynamic predictive model to estimate the hourly demand for INCIBE's 017 helpline. The results demonstrate that the XGBoost model, trained within a Walk-Forward Rolling Window algorithm of 3000 observations, significantly outperforms traditional parametric statistical models. This technique accurately captures the complex behaviour of handled calls and maintains a stability that classical approaches fail to achieve when service changes occur.

Our analysis highlights three key findings. First, the selection of a 3000-observation window offers the optimal equilibrium between metric precision and temporal adaptability. Larger windows (e.g., 7000 observations) exhibited a decreasing trend in the Coefficient of Determination, failing to adapt to structural changes in the data. Second, regarding model selection, XGBoost demonstrated superior non-parametric flexibility, maintaining a high and stable explanatory power compared to the fluctuations observed in Generalized Linear Models. Third, the optimal model achieved an overestimation ratio of 1.12. This indicates a conservative predictive behaviour that aligns with INCIBE's operational requirement for risk aversion, prioritizing the availability of operators during potential demand peaks over the minimization of average errors.

Based on these findings, we propose the design of a Real-Time Alert System that leverages the XGBoost model to monitor call volume and signal potential saturation risks. To translate this proposal into an operational reality, several lines of future work are identified. The immediate priority is the full technical implementation of the alert system, integrating the model into a dashboard via R Shiny. Additionally, future research should focus on enhancing the model's predictive capabilities by integrating external real-time data, such as internet search trends or news regarding cyberattacks, which could anticipate demand surges before they manifest in call logs. Finally, it would be relevant to evaluate Deep Learning techniques, such as Recurrent Neural Networks (e.g., LSTM or GRU), to determine whether their advanced ability to model sequential data and capture long-term temporal dependencies yields performance that surpasses the models proposed in this study.

REFERENCES

- [1] K. Żbikowski, "Using volume weighted support vector machines with walk forward testing and feature selection for the purpose of creating stock trading strategy," *Expert Systems with Applications*, vol. 42, no. 4, pp. 1797-1805, 2015.
- [2] D. Broby, "The use of predictive analytics in finance," *The Journal of Finance and Data Science*, 8, 145-161, 2022.
- [3] T. Chen and C. Guestrin, "XGBoost: A Scalable Tree Boosting System," in *Proc. 22nd ACM SIGKDD Int. Conf. Knowledge Discovery and Data Mining*, pp. 785-794, 2016.

Threat Mutation Identification via Transformer-based Analysis of Malware Assembly Code

1st Nil Ortiz Rabella
i2CAT Foundation
Barcelona, Spain
nil.ortiz@i2cat.net

2nd Albert Calvo Ibañez
i2CAT Foundation
Barcelona, Spain
albert.calvo@i2cat.net

3rd Muhammad Shuaib Siddiqui
i2CAT Foundation
Barcelona, Spain
shuaib.siddiqui@i2cat.net

Abstract—The increasing use of automated mutation and obfuscation techniques enables modern malware to evade signature-based and rule-based detection mechanisms deployed in operational security infrastructures. This work addresses the problem of threat mutation identification by leveraging Transformer-based semantic representations of assembly code combined with enriched static binary features. Malware binaries are disassembled and encoded using a pre-trained Transformer model adapted to low-level instruction sequences, producing embeddings that capture functional similarity across mutated variants. Experimental results on a large-scale, multi-family malware dataset demonstrate competitive robustness relative to representative static baselines. Beyond malware analysis, this study highlights broader challenges associated with deploying Transformer-based models in adversarial security pipelines, where learned representations constitute security-critical components subject to adaptive evasion and manipulation.

Index Terms—Malware Analysis, Threat Mutation, Transformers, BERT, Cybersecurity, AI

Tipo de contribución: *Investigación original*

I. INTRODUCTION

The rapid evolution of malware continues to challenge modern cybersecurity systems. Contemporary threats increasingly rely on polymorphism, obfuscation, and automated mutation to evade signature-based and rule-based detection mechanisms deployed in Security Information and Event Management (SIEM) platforms and endpoint protection systems. As a result, approaches based on Indicators of Compromise (IoCs) and static signatures often fail to generalise to previously unseen variants, leading to delayed detection and increased exposure to emerging attacks.

Recent advances in machine learning, particularly Transformer-based architectures, enable the learning of semantic representations of code that go beyond syntactic pattern matching. Their ability to model long-range contextual dependencies makes them well-suited for analysing sequential data such as assembly instructions, where mutation and instruction reordering can obscure surface-level patterns while preserving functionality.

In this work, we address the problem of *threat mutation identification*, defined as the detection and characterisation of malware variants originating from known families but

modified to evade conventional detection pipelines [13]. We propose a methodology that combines assembly-level representations with enriched static binary features, encoded using Transformer-based embeddings to capture functional similarities across samples. By operating at the level of low-level instructions and structural descriptors, the approach aims to identify semantic relationships between original malware and their mutated variants, even under instruction reordering, register renaming, or lightweight obfuscation.

The main contributions of this paper are threefold: (i) a feature extraction pipeline combining static binary attributes with assembly-level tokenisation for Transformer-based modelling; (ii) the adaptation of a pre-trained Transformer architecture for mutation-aware malware family classification; and (iii) an experimental evaluation on a large-scale, multi-family malware dataset, demonstrating the effectiveness of semantic embeddings for identifying mutated threats beyond signature-level similarity.

Beyond malware analysis, this work highlights the challenges of deploying Transformer-based models in adversarial environments. Malware detection pipelines operate under active adversarial pressure, where models may be targeted through evasion, poisoning, or manipulation techniques. As such, these models should be treated as security-critical components. The proposed approach therefore also serves as a case study of the trade-offs involved in deploying compact Transformer models within real-world, adversarial security infrastructures.

II. RELATED WORK

Machine learning approaches to malware detection have been widely studied, ranging from traditional feature-based classifiers to deep learning models operating on raw binaries, opcodes, or behavioural traces [1], [9]. Early methods relied on handcrafted static features, such as imported libraries, opcode frequencies, and control-flow graph metrics, combined with classifiers like support vector machines and random forests. While effective in controlled settings, these approaches are vulnerable to obfuscation and polymorphic transformations,

as minor syntactic changes can significantly alter feature distributions without affecting underlying behaviour [11], [12].

To improve robustness, representation learning techniques have been explored to capture higher-level semantic properties of malware. Convolutional neural networks have been applied to visual encodings of binaries [7], while recurrent and graph-based models have been used to analyse opcode sequences and control-flow structures [8]. Although these methods improve resilience to certain transformations, they remain sensitive to instruction reordering and often require large labelled datasets.

Transformer-based architectures address some of these limitations by modelling global dependencies through self-attention mechanisms [10]. This enables the extraction of contextual embeddings that remain stable under structural transformations, such as mutation and instruction reordering. Pre-trained models have been successfully adapted to source code and low-level instruction sequences [4], [6], and applied to tasks such as malware classification and function similarity detection [5]. However, existing work primarily focuses on classification performance over known families, with limited attention to the explicit identification of mutated variants designed to evade detection.

Hybrid approaches combining static and dynamic analysis have also been proposed to improve robustness [2], [3]. While dynamic analysis is more resilient to obfuscation, it incurs significant operational overhead and remains vulnerable to evasion techniques such as sandbox fingerprinting. Consequently, there is a need for lightweight static methods that generalise effectively to mutated malware without the complexity of dynamic analysis.

In contrast to prior work, this paper focuses explicitly on threat mutation identification by leveraging Transformer-based semantic representations of assembly code combined with enriched static binary features. By targeting semantic similarity rather than purely syntactic patterns, the proposed approach aims to bridge the gap between traditional static classification techniques and more costly dynamic analysis methods, providing a scalable solution for detecting evolving malware variants.

III. METHODOLOGY

The problem of threat mutation identification can be defined as follows. Let $\mathcal{M} = \{m_1, \dots, m_n\}$ denote a set of malware samples belonging to known families $\mathcal{F} = \{f_1, \dots, f_k\}$. A Transformer encoder $\phi_\theta(m_i) \in \mathbb{R}^d$ produces embeddings used by a classifier $f_\theta : \mathbb{R}^d \rightarrow \mathcal{F}$.

A mutation operator T transforms a sample m_i into a variant $m'_i = T(m_i)$, altering its syntax while preserving functionality. The objective is to learn representations such that $\phi_\theta(m_i)$ and $\phi_\theta(m'_i)$ remain close in the embedding space despite syntactic divergence. This extends traditional malware classification by explicitly modelling semantic similarity across mutated variants [12].

Figure 1 summarises the proposed pipeline, which combines: (i) static feature extraction, (ii) assembly-level repre-




Fig. 1. Overview of the proposed threat mutation identification pipeline. Static binary features and tokenised assembly representations are extracted in parallel, serialised into a unified sequence, and encoded using a Transformer model for malware family classification.

TABLE I
EXTRACTED STATIC BINARY FEATURES

Feature	Description
num_functions	Number of identified functions
num_imports	Number of imported symbols
num_exports	Number of exported symbols
num_strings	Number of extracted strings
num_calls	Number of call instructions
num_invalid_instructions	Invalid/disassembly errors count
num_sections	Number of PE sections
binary_size	File size in bytes
entry_point	Entry point address
min_entropy	Minimum section entropy
max_entropy	Maximum section entropy
mean_entropy	Mean entropy across sections
std_entropy	Standard deviation of entropy

sentation, and (iii) Transformer-based encoding for mutation-aware classification.

A. Representation Learning Pipeline

Each binary undergoes static analysis to extract structural and statistical features (e.g., number of functions, imports, sections, and entropy-based descriptors) [1], [11]. These features are normalised prior to training and summarised in Table I.

To capture fine-grained semantics, binaries are disassembled into assembly instruction sequences [8]. Instructions are tokenised and normalised to reduce variability from addresses, immediate values, and register naming, preserving semantic structure across mutated variants.

Static features and tokenised assembly are serialised into a unified textual sequence and encoded using a Transformer model. This early fusion allows the model to capture interactions between high-level structural attributes and low-level operational semantics. The model is initialised from a pre-trained checkpoint and fine-tuned on the malware dataset [4], [10].

B. Classification Strategy

The Transformer output is used for single-label malware family classification. The pooled embedding associated with the [CLS] token is passed through a linear classification head to predict the family label. The model is trained using cross-entropy loss, jointly optimising the encoder and classification head.

This unified representation enables the model to leverage both structural features and contextualised assembly semantics, improving robustness to syntactic mutation and lightweight obfuscation.

C. Model Architecture and Hyperparameters

The model is based on a BERT-base-uncased Transformer, fine-tuned for malware classification. Each sample is represented as a single sequence combining static features and tokenised assembly, enabling input-level feature fusion. Sequences are tokenised, padded, and truncated to a maximum length of 512 tokens.

The model is trained using standard fine-tuning settings, including cross-entropy loss, a learning rate of 5×10^{-5} , and a batch size of 8 over 3 epochs. The proposed approach performs feature fusion through textual serialisation, allowing the Transformer to learn joint representations of heterogeneous inputs.

IV. EXPERIMENTAL SETUP

This section describes the dataset, evaluation protocol, and metrics used to assess the proposed approach.

A. Dataset and Evaluation Protocol

The evaluation is conducted on a malware dataset comprising 862 families collected from publicly available repositories, with 15–20 samples per family and a total size of approximately 22 GB. The samples span the period 2020–2024.

Only families with at least 10 samples are retained to ensure sufficient representation for supervised learning. The dataset is split using a stratified 80/20 partition, preserving the class distribution across training and evaluation sets. This results in a challenging multi-class setting with moderate class imbalance and limited samples per family.

The model is fine-tuned using a standard training setup with cross-entropy loss, and performance is monitored on the held-out evaluation set at each epoch. The best-performing checkpoint is selected based on evaluation metrics.

To assess robustness to mutation, the evaluation set includes samples exhibiting syntactic divergence, such as instruction reordering and lightweight obfuscation.

B. Evaluation Metrics and Implementation Details

Performance is measured using precision, recall, and F₁-score, computed per family and in macro-averaged form. False positive and false negative rates are also reported to characterise reliability in operational settings.

All experiments are conducted offline. Static feature extraction and disassembly are performed prior to training, and representations are cached for reproducibility. Training is carried out on commodity hardware, demonstrating that mutation-aware modelling can be achieved using a compact BERT-base configuration without specialised infrastructure. Random seeds are fixed to ensure deterministic dataset partitioning and consistent results.

V. RESULTS AND EVALUATION

This section presents the experimental results of the proposed threat mutation identification approach across multiple malware families and mutation scenarios.

The method achieves strong performance across families, with accuracy ranging from 80.3% to 87.2% and F₁-scores between 76.7% and 81.8% (Table II). These results indicate effective generalisation across classes, supported by the combination of Transformer-based semantic embeddings and static binary features.

Table II reports per-family performance for a representative subset. Performance varies with intra-family diversity and obfuscation. Families such as Emotet, NjRAT, and QakBot achieve F₁-scores above 80%, whereas more heavily obfuscated families, such as TrickBot and Dtrack, exhibit lower recall (72.8% and 74.3%), reflecting reduced recoverable semantic structure.

Robustness is further evaluated on samples exhibiting syntactic divergence, including instruction reordering and lightweight obfuscation. While some degradation is observed, recall remains above 75% for several mutated families (e.g., QakBot, MoqHao), indicating that the learned representations retain discriminative power under such transformations. However, aggressive packing and control-flow obfuscation continue to degrade performance due to reduced semantic visibility.

Error analysis reveals two main sources of misclassification. False negatives are primarily associated with heavily packed or anti-disassembly samples, where limited assembly information is available. False positives occur between families sharing common code bases or libraries, leading to overlapping semantic representations. This highlights a limitation of purely static approaches in distinguishing closely related malware families without additional behavioural context.

Compared to traditional static feature-based classifiers [1], [9], the inclusion of contextual embeddings improves robustness to mutation. Several families achieve recall above 80% (e.g., Regin, NjRAT), supporting the effectiveness of semantic representations for mutation-aware malware classification.

VI. CONCLUSIONS AND DISCUSSION

This paper addressed the problem of threat mutation identification in evolving malware campaigns, where syntactic

TABLE II
PER-FAMILY PERFORMANCE FOR THREAT MUTATION IDENTIFICATION

Malware Family	Accuracy (%)	Precision (%)	Recall (%)	F1-score (%)	FPR (%)	FNR (%)
WannaCry	82.2	78.5	78.6	78.5	12.9	21.4
Regin	83.2	76.5	82.5	79.4	10.8	17.5
Emotet	87.2	79.8	80.5	80.1	9.5	19.5
TrickBot	80.3	83.6	72.8	78.0	8.5	27.2
QakBot	85.6	83.6	79.5	81.5	8.7	20.5
DarkComet	85.4	80.8	79.4	80.1	10.8	20.6
NjRAT	87.1	80.2	83.5	81.8	11.4	16.5
MoqHao	87.1	85.8	75.9	80.6	11.7	24.1
ShadowPad	82.1	76.1	81.4	78.6	15.0	18.6
Dtrack	84.4	79.2	74.3	76.7	11.4	25.7

transformations and automated mutation techniques undermine traditional signature-based detection. We proposed a methodology combining assembly-level representations, enriched static features, and Transformer-based embeddings to capture functional similarity across malware variants. Experimental results demonstrate robust performance across multiple families and improved resilience to mutation compared to purely feature-based approaches. These findings support the use of representation learning as a complementary tool for mutation-aware malware analysis, and illustrate how compact Transformer models can serve as semantic abstraction layers within security pipelines.

A. Limitations and Threats to Validity

The proposed approach depends on the availability and quality of disassembled code, which may be degraded by packing, control-flow obfuscation, or anti-disassembly techniques. In such cases, the extracted semantic signal is limited. Additionally, the evaluation relies on publicly available datasets, which may not fully reflect real-world threat distributions, introducing potential bias.

Moreover, the model captures static semantic relationships but does not explicitly account for dynamic behaviour or runtime interactions. As a result, mutations affecting execution semantics may remain difficult to detect, limiting external validity.

B. Security Implications of ML-based Malware Analysis

Malware analysis is inherently adversarial, with attackers continuously adapting through mutation and obfuscation. By leveraging semantic representations of assembly code, the proposed approach increases the difficulty of evasion by requiring modifications at the functional level rather than purely syntactic changes.

However, embedding-based models also introduce new attack surfaces. Potential threats include data poisoning, model extraction, and manipulation of training pipelines, which may distort learned representations or expose decision boundaries. While this work evaluates robustness against mutated inputs, it does not explicitly address adversarial attacks on the learning process itself.

In practice, deployment constraints often require compact models, introducing trade-offs between efficiency, robustness,

and security. Understanding the resilience of Transformer-based malware analysis systems under adversarial conditions remains an important direction for future research.

C. Future Work

Future work includes integrating dynamic analysis features (e.g., system call traces) to improve robustness against advanced obfuscation, exploring domain-specific pre-trained models for low-level code, and enabling continuous learning to address concept drift in evolving malware ecosystems.

REFERENCES

- [1] Hyrum S. Anderson and Phil Roth. Ember: An open dataset for training static pe malware machine learning models. *arXiv preprint arXiv:1804.04637*, 2018.
- [2] George Dahl, Jack Stokes, Li Deng, and Dong Yu. Large-scale behavioral analysis of malware. In *IEEE International Conference on Acoustics, Speech and Signal Processing*, 2013.
- [3] Manuel Egele, Theodoor Scholte, Engin Kirda, and Christopher Kruegel. A survey on automated dynamic malware-analysis techniques and tools. *ACM Computing Surveys*, 44(2), 2012.
- [4] Zhangyin Feng, Daya Guo, Duyu Tang, Nan Duan, Xiaocheng Feng, Ming Gong, Linjun Shou, Bing Qin, Ting Liu, and Daxin Jiang. Codebert: A pre-trained model for programming and natural languages. In *EMNLP*, 2020.
- [5] Oussama Henchiri, Nidhal Mellouli, and Mounir Rekik. Transformer-based malware classification using raw binary. In *IEEE International Conference on Cyber Security and Resilience*, 2021.
- [6] Aditya Kanade, Petros Maniatis, Gogul Balakrishnan, and Kensen Shi. Learning and evaluating contextual embedding of source code. *ICML*, 2020.
- [7] Songyang Ni, Qiang Qian, and Rui Zhang. Malware images: Visualization and automatic classification. In *2018 International Conference on Computer Science and Network Technology*, 2018.
- [8] Hao Peng, Yan Chen, and Mingwei Li. Learning malware representations for classification. In *IEEE International Conference on Big Data*, 2019.
- [9] Edward Raff, Jon Barker, Jared Sylvester, Robert Brandon, Bryan Catanzaro, and Charles Nicholas. Malware detection by eating a whole exe. In *Workshops at the Thirty-Second AAAI Conference on Artificial Intelligence*, 2018.
- [10] Ashish Vaswani et al. Attention is all you need. *NeurIPS*, 2017.
- [11] Yanfang Ye, Tao Li, Qingshan Jiang, and Yan Wang. A survey on malware detection using data mining techniques. *ACM Computing Surveys*, 50(3), 2017.
- [12] Ilgun You and Kangbin Yim. Malware detection by classification of packed executables. In *2010 International Conference on Broadband, Wireless Computing, Communication and Applications*, 2010.
- [13] Ilsun You and Kangbin Yim. Malware obfuscation techniques: A brief survey. pages 297–300, 11 2010.

Sesión de Investigación 8 - Criptografía

A Review of: A Symbolic Analysis of Hash Functions Vulnerabilities in Maude-NPA

Arturo Hernández-Sánchez

VRAIN, Universitat Politècnica de València
Camí de Vera, s/n, 46022, València, Spain
arthersan@upv.es

Santiago Escobar

VRAIN, Universitat Politècnica de València
Camí de Vera, s/n, 46022, València, Spain
sescobar@upv.es

Abstract—Maude-NPA is an analysis tool for cryptographic security protocols that takes into account the algebraic properties of the cryptosystem. Some cryptographic properties and protocols using them have been beyond Maude-NPA capabilities. Hash functions have been extensively used as a key component in cryptographic protocols, but have never been analysed in Maude-NPA. In [1], we studied some hash vulnerabilities and analyzed several protocols using Maude-NPA.

Index Terms—Hash Functions, Cryptographic Protocols, Symbolic Analysis.

Contribution type: *Research already published [1]*

I. INTRODUCTION

Maude-NPA [2] is an analysis tool for cryptographic security protocols that takes into account the algebraic properties of the cryptosystem, which can uncover vulnerabilities and, in other cases, they are part of the protocol security assumptions. This tool is based on equational unification and performs backwards search from an attack state pattern to determine whether or not it is reachable. It can be used to reason about a wide range of cryptographic properties, including bilinear pairing, exclusive-or, and some approximations of homomorphic encryption.

Hash functions have been extensively used as a key component in cryptographic protocols. They are expected to satisfy several security aspects such as *collision resistant*, i.e., the probability of having two different inputs that produce the same output is extremely low, and *pre-image resistant*, i.e., the probability of finding the right original input associated with a given hash output is extremely low. Moreover, they have commonly been assumed to be also *second pre-image resistant*, i.e., for a given input, the probability of finding another input that produces the same hash is extremely low. Essentially, the hash functions are assumed to be *perfect*, i.e., every input/output combination is completely independent of all others, which corresponds to the *Random Oracle Model (ROM)*.

In [1], we went beyond the ROM abstraction by modeling well-known hash functions vulnerabilities in Maude-NPA using equational theories, together with a protocol transformation technique that significantly reduces the attack search time. We applied this symbolic model to analyze two protocols: a variant of the SIGn and MAC (SIGMA) protocol, whose core structure resembles that of widely deployed protocols such as TLS and SSH, and the distance bounding protocol by Meadows et al. [3].

In these analyses, we automatically rediscovered the attacks on SIGMA that had previously been found in [4] using

Tamarin and ProVerif, and we additionally uncovered an attack on the Meadows protocol that had not been automatically discovered by any prior symbolic analysis tool.

II. HASH VULNERABILITIES

Hash functions are deterministic algorithms that compress an input string into a shorter one called a *digest*. In cryptography, they have various applications, such as creating message identifiers or constructing message authentication codes (MACs).

To ensure the security of protocols that rely on hash functions, these functions are expected to satisfy certain security properties. However, some hash functions that were once considered secure have later been shown to be vulnerable; that is, they were eventually found to violate one or more of the assumed security properties. To address this, we propose a symbolic model that allows us to analyze which aspects of security protocols may break if the employed hash function exhibits a given vulnerability. The vulnerabilities we modelled are listed below.

A. Chosen-Prefix Collision (CPC)

In this vulnerability, given two prefixes $P, P' \in \{0, 1\}^*$ of equal length, an adversary finds two suffixes $C, C' \in \{0, 1\}^*$ (with $C \neq C'$) such that $H(P\|C) = H(P'\|C')$, which means that $P\|C$ and $P'\|C'$ collide when applying the hash function H . If $P = P'$, this attack is called an *Identical-Prefix Collision (IPC)*.

Symbolically, we modelled this vulnerability by defining two symbolic operators cp1 and cp2 that allow the intruder to compute the suffix terms C and C' when intercepting the prefixes P and P' . The collision is specified by the following equation in the equational theory of the protocol's symbolic model:

$$H(X ; \text{cp1}(X, Y)) = H(Y ; \text{cp2}(X, Y))$$

where H denotes the symbolic operator representing the hash function.

B. Collision Extension (ColExt)

The ColExt vulnerability allows an adversary to build another type of collision. Specifically, if two inputs $x, y \in \{0, 1\}^*$ of the same length satisfy $H(x) = H(y)$, then $H(x\|s) = H(y\|s)$ for any suffix $s \in \{0, 1\}^*$. Most hash functions based on the Merkle–Damgård (MD) construction—such as MD4, MD5, SHA-1, or SHA-2—are susceptible to this vulnerability.

To represent this collision in our symbolic model, we must explicitly specify when collisions occur, i.e., when the condition $H(x) = H(y)$ holds. Thus, defining the collision extension property requires pairing it with another collision vulnerability. For example, we define ColExt together with CPC using the following equation:

$$H(X ; \text{cp1}(X, Y) ; S) = H(Y ; \text{cp2}(X, Y) ; S)$$

Since this equation does not satisfy the Finite Variant Property (FVP)—a requirement for equational theories in Maude-NPA—we bound the lengths of the messages X , Y , and S . This approach aligns with actual protocol implementations, where the lengths of messages involved in these attacks are typically bounded.

Because the attack search time was considerably high when looking for attacks that rely on this vulnerability, we also modelled it through a protocol transformation that significantly reduces search time. This transformation replaces the equational theory with dedicated Dolev–Yao rules that allow the intruder to perform the specific term transformations required for attacks based on this vulnerability.

C. Preimage Vulnerabilities

For some applications of cryptographic hash functions, it is enough to satisfy the following weaker collision-resistance properties:

- Second preimage resistance (2ndPreImg): Given a uniform $x \in \{0, 1\}^*$, the probability that a PPT adversary finds a distinct y such that $H(x) = H(y)$ is negligible.
- First preimage resistance (1stPreImg): Given $t = H(x)$ for uniform x , the probability that a PPT adversary finds any y such that $H(y) = t$ is negligible.

We model these vulnerabilities using the following equational theory and the symbolic operators `pi2` and `pi1`:

$$H(\text{pi2}(X)) = H(X) \quad H(\text{pi1}(H(X))) = H(X)$$

Essentially, the operator `pi2` allows the intruder to find a term that collides with $H(X)$ when intercepting the input X , while the operator `pi1` allows the intruder to find such a collision when intercepting the output value $H(X)$. Note that the equation $H(\text{pi2}(X)) = H(X)$ does not satisfy the FVP for a general message variable X . To ensure this property, we introduced sort restrictions on the operators `H` and `pi2`.

Another type of preimage vulnerability is the *Input Leakage* (`inLeak`), which allows an intruder to recover the input X from an intercepted hash output $H(X)$. We modelled it with the equation $\text{inLeak}(H(X)) = X$.

III. CASE STUDIES

We applied our hash vulnerability modelling to analyze two protocols: a variant of the SIGMA protocol and the Distance Bounding Protocol by Meadows et al.

For the SIGMA protocol, we automatically discovered two known attacks, $S1$ and $S3$, that had previously been identified using other symbolic tools such as Tamarin and ProVerif [4]. The first attack, $S1$, becomes feasible when the employed hash function has both the CPC and ColExt vulnerabilities. Due to the excessive execution times when searching for this attack using the equational theory approach, we also looked for it successfully using the protocol transformation approach

described in Section II-B, which significantly reduced the attack search time from 16 days to 1 hour. The second attack, $S3$, is possible under the CPC vulnerability alone, and was found in 18 minutes using the equational theory approach.

For the Meadows et al. distance bounding protocol, we automatically discovered an attack that had not been previously found with other symbolic tools. This attack becomes feasible when the protocol is instantiated with the rapid response $N_V \oplus H(P||N_P)$, a valid instantiation specified by the authors under the assumption that H is a collision-resistant hash function. In this attack, an intruder intercepts the rapid response and is able to find a collision for the digest $H(P||N_P)$ —thus breaking the collision-resistance assumption—and can then inject a forged rapid response that is later accepted as consistent with the genuine MAC-protected message from the prover. This attack was found in 20 minutes when the employed hash function has the 1stPreImg vulnerability, or in 3 hours when it exhibits both the 2ndPreImg and inLeak vulnerabilities.

IV. CONCLUSIONS

In this paper, we reproduced the attack $S1$ of the SIGMA protocol using an event-based approach. Also, we reproduced the attacks $S1$ and $S3$ of the SIGMA protocol using equational unification. We identified a vulnerability of the Meadows et al. protocol not found previously by any symbolic tool using equational unification. Finally, we seamlessly combined different algebraic properties, including associativity, without incompleteness warnings and in reasonable analysis time. As future work, we plan to investigate other protocols and hash functions vulnerability dimensions.

ACKNOWLEDGMENTS

This work has been partially supported by the grant PID2024-162030OB-I00 funded by MCIN/AEI/10.13039/501100011033 and ERDF A way of making Europe, by the grant CIPROM/2022/6 funded by Generalitat Valenciana, and by the NATO Science for Peace and Security Programme project SymSafe (grant number G6133).

REFERENCES

- [1] A. Hernández-Sánchez and S. Escobar, “A symbolic analysis of hash functions vulnerabilities in Maude-NPA,” in *Computer Security - ESORICS 2025 - 30th European Symposium on Research in Computer Security, Toulouse, France, September 22-24, 2025, Proceedings, Part II*, ser. Lecture Notes in Computer Science, V. Nicomette, A. Benzekri, N. Boulahia-Cuppens, and J. Vaidya, Eds., vol. 16054. Springer, 2025, pp. 186–204. [Online]. Available: https://doi.org/10.1007/978-3-032-07891-9_10
- [2] S. Escobar, C. Meadows, and J. Meseguer, “Maude-NPA: Cryptographic protocol analysis modulo equational properties,” in *Foundations of Security Analysis and Design V, FOSAD 2007/2008/2009 Tutorial Lectures*, ser. Lecture Notes in Computer Science, A. Aldini, G. Barthe, and R. Gorrieri, Eds., vol. 5705. Springer, 2007, pp. 1–50. [Online]. Available: https://doi.org/10.1007/978-3-642-03829-7_1
- [3] C. Meadows, R. Poovendran, D. Pavlovic, L. Chang, and P. Syverson, “Distance bounding protocols: Authentication logic analysis and collusion attacks,” in *Secure localization and time synchronization for wireless sensor and ad hoc networks*. Springer, 2007, pp. 279–298.
- [4] V. Cheval, C. Cremers, A. Dax, L. Hirschi, C. Jacomme, and S. Kremer, “Hash gone bad: Automated discovery of protocol attacks that exploit hash function weaknesses,” in *32nd USENIX Security Symposium, USENIX Security 2023, Anaheim, CA, USA, August 9-11, 2023*, J. A. Calandrino and C. Troncoso, Eds. USENIX Association, 2023, pp. 5899–5916. [Online]. Available: <https://www.usenix.org/conference/usenixsecurity23/presentation/cheval>

Simulación cuántica de lógica booleana, circuitos digitales y esquemas criptográficos

Daniel Escanez-Exposito
Universidad de La Laguna
Tenerife, España
jescañez@ull.edu.es

Pino Caballero-Gil
Universidad de La Laguna
Tenerife, España
pcaballe@ull.edu.es

Resumen—El artículo describe una implementación novedosa de una biblioteca para la simulación cuántica de circuitos booleanos típicos y varios sistemas de cifrado. La herramienta contiene media suma y suma completa, codificador binario (de 2^n a n), decodificador binario (de n a 2^n) y multiplexor, así como los detalles de su desarrollo acompañados de gráficos generados por el propio software. Estas herramientas son esenciales para la implementación de varios cifrados clásicos y actuales. Además, se incluyen estudios de optimización para el paradigma cuántico de sistemas de cifrado simétrico de diferentes tipos, tales como cifrados por sustitución o por permutación y una versión simplificada de AES (S-AES). Este enfoque permite una comprensión simple e intuitiva de los circuitos cuánticos equivalentes a los fundamentos de la electrónica digital y el diseño lógico, proporcionando una herramienta innovadora y pedagógica que posibilita la implementación cuántica de circuitos clásicos para aplicaciones reales, incluidos sistemas de cifrado complejos, partiendo de algoritmos previamente definidos.

Index Terms—Computación cuántica, Simulación cuántica de circuitos clásicos, Herramienta cuántica para lógica booleana, Criptografía cuántica, S-AES

Tipo de contribución: Investigación ya publicada

Daniel Escanez-Exposito, Pino Caballero-Gil, Quantum simulation of Boolean logic, digital circuits, and cryptographic schemes, Logic Journal of the IGPL, Volume 34, Issue 1, February 2026, jzaf019, <https://doi.org/10.1093/jigpal/jzaf019>.

I. INTRODUCCIÓN

El trabajo se enmarca en la era digital actual y futura, donde convergen inteligencia computacional, lógica aplicada, criptografía, seguridad de la información y computación cuántica, áreas que se combinan en una aproximación integradora mediante la ampliación de la biblioteca QuantumSolver [1], desarrollada sobre Qiskit [2] por los autores de la presente propuesta, para facilitar su aplicación en seguridad de la información, lógica aplicada y criptografía. QuantumSolver, accesible tanto vía interfaz web como línea de comandos, incluye algoritmos cuánticos como generación de números aleatorios, Grover, teleportación cuántica y codificación superdensa, ejecutables en simuladores y ordenadores cuánticos reales de IBM. Además incluye protocolos criptográficos BB84, E91 y B92. El artículo se centra en reforzar y ampliar el módulo QuantumSolver Composer, ofreciendo una herramienta práctica que facilite el aprendizaje y la programación de circuitos cuánticos a partir de sus equivalentes clásicos.

II. CIRCUITOS LÓGICOS Y ARITMÉTICOS COMBINACIONALES

Esta sección presenta la implementación cuántica de varios circuitos lógicos y aritméticos combinacionales fundamentales

[3], los cuales sirven como bloques estructurales para los esquemas criptográficos desarrollados posteriormente. Debido a las restricciones del paradigma cuántico, todos los diseños deben ser reversibles, lo que implica igualar el número de entradas y salidas y emplear registros auxiliares para almacenar resultados intermedios [4], [5].

- **Medio sumador y sumador completo:** Implementan suma y acarreo con operaciones XOR y AND reversibles; el sumador completo añade acarreo de entrada y cúbits auxiliares.
- **Codificador binario:** Convierte una entrada activa en su representación binaria mediante lógica reversible, conservando los registros.
- **Decodificador binario:** Activa una única salida a partir de una entrada binaria usando operaciones reversibles auxiliares.
- **Multiplexor:** Selecciona una entrada según un registro selector, garantizando coherencia y reversibilidad.

III. MÉTODOS DE CIFRADO IMPLEMENTADOS

III-A. Cifrados por Sustitución

Los cifrados por sustitución son técnicas criptográficas en las que cada carácter del texto en claro se reemplaza por otro según una regla definida por una clave secreta, estableciendo una correspondencia sistemática entre alfabetos y aportando la propiedad de confusión descrita por Claude Shannon [6]. Entre sus variantes se distinguen los esquemas monoalfabéticos y polialfabéticos, representados respectivamente por el Cifrado César y el Cifrado de Vigenère, mientras que el cifrado de Vernam constituye un caso paradigmático. En los tres casos, el proceso puede implementarse mediante una operación XOR entre mensaje y clave, cuya equivalencia cuántica es la puerta CNOT, dando lugar a circuitos basados en la aplicación sistemática de dichas puertas entre los registros correspondientes (véase Fig. 1).




Figura 1. Circuito cuántico para cifrado de sustitución

III-B. Cifrado por Permutación

El cifrado por permutación o transposición consiste en reorganizar los símbolos del texto en claro según una clave que define una regla de reordenamiento, sin alterar su naturaleza. Este tipo de cifrado ejemplifica la propiedad de difusión, también formulada por Claude Shannon [7], al dispersar la influencia de cada símbolo a lo largo del texto cifrado para dificultar el análisis estadístico. Su implementación cuántica se basa en un circuito que emplea tres registros (mensaje, clave y un registro auxiliar inicializado con el mensaje), siendo este último el que proporciona la salida tras aplicar la permutación correspondiente (véase Fig. 2).




Figura 2. Circuito cuántico para cifrado de permutación

III-C. AES Simplificado (S-AES)

El Estándar de Cifrado Avanzado (del inglés, *Advanced Encryption Standard*, AES) es el algoritmo de cifrado más relevante en la actualidad y base de la mayoría de las tecnologías de comunicación, destacando por su robustez, eficiencia y versatilidad en la protección de datos. Puede considerarse resistente en la era cuántica, ya que sus operaciones no se ven comprometidas por el algoritmo de Shor y, frente al algoritmo de Grover, mantiene su nivel de seguridad mediante el uso de claves de longitud doble. No obstante, su implementación cuántica completa no es viable con el hardware actual debido a las limitaciones en número y calidad de cúbits y a la complejidad de simulación, por lo que se adopta una versión simplificada, S-AES, con bloques de 16 bits y dos rondas [8], [9], [10], integrada en QuantumSolver Composer.

El esquema cuántico reducido comienza con la operación AddRoundKey (XOR entre mensaje y clave), seguida de la transformación S-Box implementada con puertas reversibles (véase Fig. 3); ShiftRows se realiza mediante intercambios de cúbits y MixColumns se optimiza para reducir operaciones CNOT y mejorar el uso de registros, mientras que la expansión de clave emplea primitivas de Qiskit. Finalmente, se llevaron a cabo pruebas de cifrado que validan la consistencia y corrección de la implementación cuántica automatizada desarrollada.




Figura 3. Circuito cuántico para S-Box

IV. DISCUSIÓN

QuantumSolver Composer es una herramienta pedagógica de código abierto para describir circuitos cuánticos a partir de definiciones clásicas de bajo nivel, priorizando un enfoque automático y explicable que facilita el aprendizaje, aunque limita su eficiencia frente a optimizaciones diseñadas directamente desde el paradigma cuántico. En esta primera etapa se ha optado por un marco modular que permita incorporar mejoras progresivas, utilizando además la instrucción `reset` para reducir cúbits auxiliares sin afectar a los registros de entrada; como trabajo futuro, se plantea una versión que elimine `reset` y adopte técnicas sistemáticas de descomputación.

V. CONCLUSIONES Y PROBLEMAS ABIERTOS

En este trabajo se ha presentado una implementación novedosa para la simulación cuántica de circuitos booleanos y sistemas de cifrado mediante el desarrollo de una biblioteca que integra sumadores, codificadores, decodificadores y multiplexores, empleada como base para la implementación cuántica de diversos cifrados clásicos y modernos, incluida una versión simplificada del Advanced Encryption Standard (AES), proporcionando en cada caso tanto el código como la representación de los circuitos para favorecer una comprensión intuitiva; como líneas futuras, se propone incorporar otros algoritmos simétricos como ChaCha20, explorar esquemas asimétricos y realizar estudios comparativos de rendimiento frente a otras herramientas de simulación cuántica para evaluar su eficiencia y aplicabilidad práctica.

AGRADECIMIENTOS

La presente publicación ha sido posible gracias a la Cátedra Binter en Ciberseguridad de la Universidad de La Laguna y a los proyectos de investigación PID2022-138933OB-I00 ATQUE y 2023DIG28 IACTA financiados por MCIN/AEI/10.13039/501100011033/FEDER EU, y la Fundación CajaCanarias “la Caixa”, respectivamente.

REFERENCIAS

- [1] D. Escanez-Exposito, “GitHub QuantumSolver repository,” 2022. [Online]. Available: <https://github.com/jdanielescanes/quantum-solver>
- [2] A. Javadi-Abhari, M. Treinish, K. Krsulich, C. J. Wood, J. Lishman, J. Gacon, S. Martiel, P. D. Nation, L. S. Bishop, A. W. Cross, B. R. Johnson, and J. M. Gambetta, “Quantum computing with Qiskit,” 2024.
- [3] R. Tokheim, *Schaum's Outline of Digital Principles*. McGraw-Hill, Inc., 1994.
- [4] C. H. Bennett, “Logical reversibility of computation,” *IBM journal of Research and Development*, vol. 17, no. 6, pp. 525–532, 1973.
- [5] M. Swathi and B. Rudra, “Implementation of reversible logic gates with quantum gates,” in *IEEE 11th annual computing and communication workshop and conference*, 2021, pp. 1557–1563.
- [6] C. E. Shannon, “A mathematical theory of communication,” *The Bell system technical journal*, vol. 27, no. 3, pp. 379–423, 1948.
- [7] —, “Communication theory of secrecy systems,” *The Bell system technical journal*, vol. 28, no. 4, pp. 656–715, 1949.
- [8] M. A. Musa, E. F. Schaefer, and S. Wedig, “A simplified aes algorithm and its linear and differential cryptanalyses,” *Cryptologia*, vol. 27, no. 2, pp. 148–177, 2003.
- [9] M. Almazrooie, R. Abdullah, A. Samsudin, and K. N. Mutter, “Quantum grover attack on the simplified-aes,” in *7th International Conference on Software and Computer Applications*, 2018, pp. 204–211.
- [10] K.-B. Jang, G.-J. Song, H.-J. Kim, and H.-J. Seo, “Grover on simplified aes,” in *IEEE International Conference on Consumer Electronics-Asia*, 2021, pp. 1–4.

A generalized approach towards root-based attacks against PLWE instances

Iván Blanco Chacón¹, Raúl Durán Díaz¹ and
Rodrigo Martín Sánchez-Ledesma^{2,3}

¹Universidad de Alcalá, Alcalá de Henares, Spain, {ivan.blancoc, raul.duran}@uah.es

²Universidad Complutense de Madrid, Madrid, Spain, rodrma01@ucm.es

³Indra Sistemas de Comunicaciones Seguras, Madrid, Spain, rmsanchezledesma@indra.es

Abstract—The present work is an extended abstract of [1], which deals with the robustness of the Polynomial Learning With Errors problem extending previous results in [2]. We explain here the attacks presented therein focusing on the case where the defining polynomial of degree N has a root of degree $n < N$, thus allowing us to determine further previously-not-detected dangerous instances.

Index Terms—PLWE, PQC, Trace map, Number Theory

I. INTRODUCTION

Lattice-based cryptography has achieved an extraordinary success in the last years, especially since NIST launched a public contest in 2017 to standardize different sets of quantum-resistant primitives. With five candidates selected for standardization, three of them belong to the lattice-based category (i.e. ML-KEM, ML-DSA and FN-DSA).

In the present work, we are concerned in particular with the Polynomial Learning With Errors problem, which was introduced in [3]. Let us denote by R the quotient ring $R := \mathbb{Z}[x]/(f(x))$ with $f(x) \in \mathbb{Z}[x]$ of degree N , monic and irreducible over $\mathbb{Z}[x]$, and let $q \geq 2$ be a prime. Set $R_q := \mathbb{F}_q[x]/(f(x))$ and consider an R_q -valued uniform random distribution U and an R_q -valued discrete Gaussian distribution χ_{R_q} . The PLWE problem in decision form, the version we investigate in this work, consists in guessing, with non-negligible advantage, if a set of pairs $\{(a_i(x), b_i(x))\}_{i \geq 1} \subseteq R_q \times R_q$ of arbitrary size has been sampled either from $U \times U$ or from the PLWE distribution, where each sample is defined as $(a_i(x), b_i(x)) = (a_i(x)s(x) + e_i(x))$, with $e_i(x)$ sampled from χ_{R_q} and $s(x) \in R_q$ a secret value.

The main contribution of the present work is to completely generalize the extension idea presented in [4] against the attacks developed by [2].

The key tool of these extensions is to combine the evaluation-at- α map with the trace map [4]. This composition of maps allows one to project R_q to a subring $R_{q,0}$ of large enough dimension over which the PLWE problem turns solvable in expected polynomial time with overwhelming probability of success. Then, the composition is suitably applied to each *distinguishability condition* in [2], depending upon the attack to be extended.

We show that this idea can be extended beyond purely quadratic extensions, and is applicable to all three types of attacks in [5].

II. ORIGINAL ROOT-BASED ATTACKS AGAINST PLWE

In [2] and [5], the authors describe an attack against the PLWE problem attached to a quotient ring R_q and a prime q , if there exists a root $\alpha \in \mathbb{F}_q$ (i.e. $n = 1$) such that either

- a) $\alpha = 1$, or
- b) α has *small set of possibilities* modulo q , or
- c) α has *small residue* modulo q .

For any of the cases above, the idea of the attacks is the same: the samples to be distinguished are transferred from R_q into $\mathbb{F}_q$ via a certain morphism Φ , in such a way that *distinguishability features* are transferred as well.

Each particular feature to be tried is represented by one of the cases above, which will define a different distinguishability set Σ . A complete analysis of all the attacks can be found in [1].

III. EXTENSIONS VIA THE TRACE OPERATOR

The applicability of the preceding attacks depends both on the conditions of q and on the order of the roots of $f(x)$ in $\mathbb{F}_q$ but they are restricted to roots belonging strictly to $\mathbb{F}_q$.

Most PLWE schemes want their polynomials to be fully split in order to optimize polynomial multiplications, typically via NTT. However, this is not always the case and the best-known example is ML-KEM, whose defining polynomial does not fully split in $\mathbb{F}_q$ for the standardized q .

Such scenarios boost the interest of finding ways to generalize the attacks described above to polynomials that do not factor directly over $\mathbb{F}_q$ but rather over a finite field extension. To introduce this new setting, suppose now that the following conditions are met:

- There exists $a \in \mathbb{F}_q$ such that the polynomial $x^n - a$ divides $f(x)$ in $\mathbb{F}_q[x]$ and, therefore, $n < N$.
- The polynomial $x^n - a$ is irreducible over $\mathbb{F}_q[x]$, i.e., $f(x)$ has an irreducible factor of degree n .
- The element a has a small multiplicative order in $\mathbb{F}_q^*$.

We choose $\alpha \in \mathbb{F}_{q^n} \setminus \mathbb{F}_q$ such that its minimal polynomial over $\mathbb{F}_q$ is precisely $x^n - a$. We define now

$$R_{q,0} = \{p(x) \in R_q : p(\alpha) \in \mathbb{F}_q\}.$$

To generalize the attacks to roots in arbitrary degree extensions of $\mathbb{F}_q$, we need to *upgrade* the morphism Φ used in the previous section, so that its image still remains in $\mathbb{F}_q$.

In order to achieve this goal, the homomorphism Φ will be the composition of the evaluation homomorphism with the

trace map, $\Phi: R_q \rightarrow \mathbb{F}_q$, defined as

$$\Phi := \text{Tr} \circ \text{ev}_\alpha.$$

In addition to allowing the construction of such a morphism, the trace map also provides

Proposition 1: Suppose that $x^n - a$ divides $f(x)$ over $\mathbb{F}_q[x]$ for some $n < N$. Assume that $x^n - a$ is irreducible over $\mathbb{F}_q[x]$ and let $\alpha \in \mathbb{F}_{q^n} \setminus \mathbb{F}_q$ be a root of $f(x)$. Then, for each $j \geq 1$ such that j is not a multiple of n we have that $\text{Tr}(\alpha^j) = 0$.

A. Attack over the subring $R_{q,0}$, generalized

The attacks are (mostly) carried out by Algorithm 1, whose input is a set of samples S coming from $R_{q,0} \times R_q$ and allowing one to distinguish whether such set is drawn either from the uniform or from the PLWE distribution.

Input: A set S of M samples $\in R_{q,0} \times R_q$
A distinguishability set Σ

- $G := \emptyset$
 - for $g \in \mathbb{F}_q$ do
 - for $(a_i(x), b_i(x)) \in S$ do
 - * if $\frac{1}{n}(\text{Tr}(b_i(\alpha)) - a_i(\alpha)g) \notin \Sigma$ then next g
 - $G := G \cup \{g\}$
 - if $G = \emptyset$ then return **NOT PLWE**
 - if $|G| = 1$ then return **PLWE**
 - if $|G| > 1$ then return **NES**
-

Algorithm 1. Generic Root-based attack framework over finite extensions of $\mathbb{F}_q$

Observe that if $(a(x), b(x) = a(x)s(x) + e(x)) \in R_{q,0} \times R_q$ is a PLWE sample, evaluating it at α yields $\text{Tr}(b(\alpha) - a(\alpha)s(\alpha)) = \text{Tr}(e(\alpha))$. Computing the latter

$$\text{Tr}(e(\alpha)) = \sum_{j=0}^{N'-1} e_{nj} \cdot \text{Tr}(\alpha^{nj}) = n \cdot \sum_{j=0}^{N'-1} e_{nj} \cdot a^j, \quad (1)$$

with $N' = \frac{N}{n}$ and, for simplicity, $n \mid N$. Assuming that r is the multiplicative order of a in $\mathbb{F}_q^*$, let us define $N'' = \frac{N'}{r}$ and, again for simplicity, suppose that $r \mid N'$. Thus we eventually obtain

$$\text{Tr}(e(\alpha)) = n \sum_{i=0}^{r-1} a^i \cdot \sum_{j=0}^{N''-1} e_{n(jr+i)}. \quad (2)$$

Since $a(x) \in R_{q,0}$,

$$\text{Tr}(b(\alpha) - a(\alpha) \cdot s(\alpha)) = \text{Tr}(b(\alpha)) - a(\alpha) \text{Tr}(s(\alpha)).$$

where the only unknown is precisely $\text{Tr}(s(\alpha)) \in \mathbb{F}_q$. This fact allows our algorithm to loop over $\mathbb{F}_q$ rather than over the full ring R_q .

Proposition 2: Let Σ , M and r be defined as above, and assume $|\Sigma| < q$. Then:

- 1) If Algorithm 1 returns **PLWE** or **NES**, then the algorithm guesses correctly with probability at least $1 - q \left(\frac{|\Sigma|}{q}\right)^M$.
- 2) If Algorithm 1 returns **NOT PLWE**, then the algorithm guesses correctly with probability 1.

For the not truncated case, we have the following

Corollary 3: With the same notations and assumptions as in Proposition 2,

- 1) If the samples are PLWE, Algorithm 1 guesses correctly with probability at least p_0^{Mr} .
- 2) If the samples are uniform, Algorithm 1 guesses correctly with probability at least $1 - q \left(\frac{|\Sigma|}{q}\right)^M$.

Note that, in the case of attack b), the distinguishability set Σ will represent

$$\Sigma := \left\{ \sum_{j=0}^{r-1} x_j \alpha^j : x_j \in [-2\bar{\sigma}, 2\bar{\sigma}] \cap \mathbb{Z} \right\},$$

while on attack c), we will consider

$$\Sigma := \left[\frac{-q}{4}, \frac{q}{4} \right),$$

While for attack b) there are no utter requirements, for the application of attack c), we must further have $2\bar{\sigma} \leq \frac{q}{4}$. If it is not verified, [5] defined yet another attack in $\mathbb{F}_q$, which we now generalize to arbitrary extensions.

Let E_i denote the event that $\frac{1}{n} \text{Tr}(b_i(\alpha) - g \cdot a_i(\alpha)) \in \left[\frac{-q}{4}, \frac{q}{4} \right)$ for the i -th sample and fixed g , and the probability as $P(E_i | D = \mathcal{G}_\sigma) := \frac{1}{2} + \delta$. Further, define

$$\mu(q) = \begin{cases} 1 & : q \equiv 1 \pmod{4} \\ -1 & : q \equiv 3 \pmod{4} \end{cases}$$

Then, we have

Input: A collection of samples $S \subseteq R_{q,0} \times R_q$
A value δ .

- $T := \left\lfloor \frac{1}{2} \left(\ell \cdot q + 2\ell \cdot \delta \mu(q) \ell \cdot \left(1 - \frac{1}{q} \right) \right) \right\rfloor$
 - $C := 0$
 - for $g \in \mathbb{F}_q$ do
 - for $(a_i(x), b_i(x)) \in S$ do
 - * if $\frac{1}{n}(\text{Tr}(b_i(\alpha)) - a_i(\alpha)g) \in \left[-\frac{q}{4}, \frac{q}{4} \right)$ then
 - $C = C + 1$
 - if $C < T$ then return **UNIFORM**
 - else return **PLWE**
-

Algorithm 2. Unbounded Small Values Attack over finite extensions of $\mathbb{F}_q$

Lemma 4: Let C, T, δ be as specified in Algorithm 2. Then, if $\frac{\mu(q)}{2q} < \delta$, then the above algorithm is successful.

REFERENCES

- [1] I. Blanco-Chacón, R. Durán-Díaz, and R. M. Sánchez-Ledesma, “A Generalized Approach to Root-based Attacks against PLWE,” *Cryptography and Communications: Special Issue QuRCry*, 2025.
- [2] Y. Elias, K. E. Lauter, E. Ozman, and K. E. Stange, “Provably Weak Instances of Ring-LWE,” in *Advances in Cryptology – CRYPTO 2015*, ser. Lecture Notes in Computer Science, R. Gennaro and M. Robshaw, Eds., no. 9215. Berlin, Heidelberg: Springer Berlin Heidelberg, 2015, pp. 63–92.
- [3] D. Stehlé, R. Steinfeld, K. Tanaka, and K. Xagawa, “Efficient Public Key Encryption Based on Ideal Lattices,” in *Advances in Cryptology – ASIACRYPT 2009*, M. Matsui, Ed. Berlin, Heidelberg: Springer Berlin Heidelberg, 2009, pp. 617–635.
- [4] B. Barbero-Lucas, I. Blanco-Chacón, R. Durán-Díaz, R. Martín Sánchez-Ledesma, and R. Y. Njah Nchiwo, “Cryptanalysis of PLWE based on zero-trace quadratic roots,” arXiv, 2025.
- [5] Y. Elias, K. E. Lauter, E. Ozman, and K. E. Stange, “Ring-LWE Cryptography for the Number Theorist,” in *Directions in Number Theory*, ser. Association for Women in Mathematics Series, E. E. Eischen, L. Long, R. Pries, and K. E. Stange, Eds., vol. 3. Cham: Springer International Publishing, 2016, pp. 271–290.

Formalization and analysis of the post-quantum signature scheme FALCON with Maude

Víctor García

VRAIN, Universitat Politècnica de València
Valencia, Spain
vicgarval@upv.es

Santiago Escobar

VRAIN, Universitat Politècnica de València
Valencia, Spain
sescobar@upv.es

Kazuhiro Ogata

Japan Advanced Institute of
Science and Technology
Ishikawa, Japan
ogata@jaist.ac.jp

Abstract—Digital signatures ensure the authenticity and integrity of digital assets, vital properties for any secure communication. The National Institute of Standards and Technologies launched the Post-Quantum Cryptography project to standardise new algorithms and protocols that are secure against quantum attackers. The post-quantum signature scheme FALCON was one of the finalists. We present in [1] the first steps towards the formal specification and analysis, in the high-performance language Maude, of signature schemes. We adapted and improved a previous framework, originally aimed to formally specify and analyse post-quantum key encapsulation mechanisms. As a use case of the new framework, we specify an executable symbolic model of FALCON. On the symbolic model, we verify termination and fairness using LTL formulas with Maude’s model checker. Furthermore, authentication, integrity and non-repudiation are analysed through invariant analysis. Integrity and non-repudiation hold, meanwhile, authentication does not hold in our symbolic model.

Index Terms—Formal Methods, Post-quantum, Signature scheme, FALCON, Maude

Contribution type: Research already published

I. INTRODUCTION

Digital signature schemes are a cryptography building block that provides authentication and integrity to the system where it is enforced. The security of the most used digital signature schemes is based on computational problems hard to solve for classic computers, such as the prime factorization and discrete logarithm problems. However, quantum algorithms, like Shor’s prime factorization, can provide solutions to these hard computational problems when executed on computers with quantum capabilities.

In [1], we present further steps towards modelling signature schemes by reusing and adapting a framework previously developed for Key Encapsulation Mechanisms. Specifically, we showed how the framework can handle signature schemes by using FALCON as a use case. The use case will consisted of building an executable symbolic model that simulates execution traces and allows us to perform exhaustive reasoning. All the specifications presented in this paper can be found in the GitHub repository at: <https://github.com/v1ct0r-byte/PQC-in-Maude/>.

II. FALCON

Fast-Fourier Lattice-based Compact Signatures over NTRU (FALCON) is a signature scheme based on lattices to sign and verify messages. The main components of the scheme are a class of cryptography lattices, the NTRU class is chosen, and a trapdoor sampler, for which a new technique was developed, the fast Fourier sampling. Concrete algorithms for each of the

main three functions are presented in Figure 1, and will serve as guidelines to our Maude specifications.

First, **KeyGen** produces a public-private key pair using two inputs, ϕ and q , which act as seeds for computing the polynomials f , g , F , and G . These polynomials form a matrix from which the FALCON tree is derived. The secret key is the pair $sk = (\hat{B}, T)$, consisting of the normalized matrix and the tree. The public key is the value $h = gf^{-1} \bmod q$, obtained by multiplying g with the inverse of f modulo q .

Next, the **Sign** algorithm takes a message and the secret key. A bound β would normally be included but is omitted per the assumption given in Section III-A. A random salt r is sampled and concatenated with the message to produce a hash value c . Using c and the secret key, the algorithm computes values s_1 and s_2 . The value s_2 is then compressed, and the signature is the pair $sig = (r, s)$, where s is the compressed version of s_2 .

Finally, **Verify** checks a message-signature pair using the sender’s public key. Again we omit the bound β per the assumption given in Section III-A. The algorithm recomputes c from the received message m and the salt r . It then reconstructs s_1 and s_2 , decompressing s to obtain the latter. Using the public key and the recomputed values, s_1 is regenerated according to the scheme’s formula in step three. If the recomputed s_1 and s_2 match those implied by the signature, the signature is valid for the message; otherwise, it is rejected.




Fig. 1. FALCON internal algorithms adapted from [1].

III. ANALYSIS

This section covers the verification performed over the symbolic model of FALCON. First, we describe the different assumptions our model relies on. Then, we explain the verification step involving invariant analysis for a set of three properties: Authentication, Integrity and Non-repudiation. Then we pass on to the use of Maude's model checker to verify termination and fairness of our model.

A. Assumptions

When symbolically modelling a protocol, one can abstract himself from computational aspects to make the specifications simpler and easier to understand. Imposing abstractions clears the way to reason and analyse the problem at hand, at the cost of making the model less representative of the real world. The assumptions we make for our symbolic specification over the computational model are the following.

- Any generated polynomials f, g, F and G (resp. f', g', F' and G') always satisfy the equational property $fG - gF = q \mod \phi$ (resp. $f'G' - g'F' = q \mod \phi$).
- The signature and verification algorithms always operate within the parameter β , thus β is not deemed necessary in the specification of these algorithms.
- Validity of s_1 and s_2 (resp. s'_1 and s'_2) in signature and validation algorithms. In other words, signature validation of a well-constructed signature for a valid message does not fail. The combination of both the previous assumption and this one, allow us to avoid the case where the signature and verification algorithms fail and return "Reject"; see Figure 1.

B. Invariant analysis

Authentication, integrity and non-repudiation are key in any signature scheme. In order to prove them we decided to use invariant analysis, which is a form of model checking where we *check* for states in which the properties does not hold. If no states are found, we can say with assurance that the model holds the property.

1) *Authentication*: We state that a signature provides authentication if there is a proof of the sender having the private key and signing the message with it. A more detailed description is that the receiver of the signature should not be able to verify a message if it has not been signed by the sender first. This has a direct implication on the execution of the algorithm, where the procedure to verify a message cannot be performed before the procedure to sign it. To prove authentication we search for paths in which a message has been verified without it being signed at first by the other participant.

2) *Integrity*: Integrity can be defined as a proof of a message not being modified after the signature generation process. We can explain this as an invariant declaring that a message verified by the receiver is the same that the sender generated and signed.

3) *Non-repudiation*: The property of non-repudiation in a system is a proof of a participant not being able to deny the signature for a message he has signed. Another way to explain this is, whenever a signature is created, the sender can not deny it in the future. Here the invariant is that for any message

with a signature, the signature and message can be linked to the signer.

C. Model Checking

We use Maude's LTL model checker to prove termination and fairness over our symbolic model. We first introduce a natural language description of each property, to then give the corresponding LTL formula.

1) *Termination*: We define termination of a program implementing a signature scheme as the eventual application of the verification algorithm. This can be modelled in our system with the LTL formula $\Diamond \text{verifiedSignatureFrom}(ID1, ID2)$. Predicate $\text{verifiedSignatureFrom}(ID1, ID2)$ states that $ID1$ has verified a message with a signature from $ID2$.

2) *Fairness*: Fairness is defined as that whenever a participant wants to do something, they can do so infinitely many often. In the signature schemes case, it is stated as that whenever the sender wants to send a signed message to the receiver, the receiver will eventually verify it. We model the property by the LTL formula

$$\begin{aligned} & \Box (\text{wantsToSignAndSendTo}(ID1, ID2) \\ & \rightarrow \\ & \Diamond \text{verifiedSignatureFrom}(ID1, ID2)). \end{aligned}$$

Predicate $\text{wantsToSignAndSendTo}(ID1, ID2)$ states that $ID1$ wants to sign and send a message to $ID2$.

D. Results

All the above properties hold for our symbolic model of FALCON except Authentication. Authentication fails due to the presence of a man-in-the-middle attack. As a solution we suggest improving the public key distribution to support some kind of validation that avoids modification mid-air.

IV. CONCLUSION

We used Maude to build an executable model of FALCON and perform symbolic analysis to verify properties of interest. Specifically, we specified the three main algorithms of FALCON and constructed a system with two honest participants and an intruder. Over the symbolic model, two kinds of formal analysis were carried on. On the one hand, with invariant analysis we tried to prove authentication, integrity and non-repudiation in our executable model of FALCON. Only integrity and non-repudiation hold in our symbolic model. On the other hand, we used Maude's LTL model checker to prove termination and fairness of our symbolic specification.

ACKNOWLEDGMENTS

Santiago Escobar and Víctor García have been partially supported by the grant PID2024-162030OB-I00 funded by MCIN/AEI/10.13039/501100011033 and ERDF A way of making Europe, by the grant CIPROM/2022/6 funded by Generalitat Valenciana, and by the NATO Science for Peace and Security Programme project SymSafe (grant number G6133).

REFERENCES

- [1] V. García, S. Escobar, and K. Ogata, "Formalization and analysis of the post-quantum signature scheme falcon with maude," *Journal of Logical and Algebraic Methods in Programming*, vol. 143, p. 101034, 2025. [Online]. Available: <https://doi.org/10.1016/j.jlamp.2024.101034>

Una revisión de: Building a large, realistic and labeled URI dataset for website modelling in anomaly-based intrusion detection systems: Biblio-US17

Jesús E. Díaz-Verdejo*, Rafael Estepa†, Antonio Estepa†, Fco. Javier Muñoz-Calle†, Germán Madinabeitia†

* Dpt. Teoría de Señal, Telemática y Comunicaciones, CITIC, Univ. de Granada
C/ Periodista Daniel Saucedo Aranda, s/n, 18071 Granada (Spain)

E-mail: jedv@ugr.es

† Dpt. Ingeniería Telemática, Escuela Superior de Ingenieros, Univ. de Sevilla
C/ Camino de los Descubrimientos s/n, 41092 Sevilla (Spain)

E-mail: {vmayor, rafa, aestepa}@trajano.us.es

Resumen—Este trabajo presenta la creación, depuración y validación de Biblio US17, un conjunto de datos exhaustivo y etiquetado con 47 millones de peticiones HTTP, obtenido durante seis meses de operación del servidor web de la Biblioteca de la Universidad de Sevilla. Esta contribución se enmarca en la creciente necesidad de datasets realistas, recientes y etiquetados que permitan evaluar con rigor los sistemas de detección de intrusiones basados en anomalías (AIDS) en el contexto de ataques web que se manifiestan en los Uniform Resource Identifiers (URI).

Cada registro ha sido etiquetado como normal o de ataque tras un exhaustivo proceso semiautomatizado que incluyó la detección basada en firmas y la detección de anomalías en el vocabulario observado en las URI. Se describen los procesos de recopilación y etiquetado, la estructura del conjunto de datos y las propiedades más relevantes. El dataset resultante está disponible públicamente.

Index Terms—Adquisición de datos, conjuntos de datos de entrenamiento

Tipo de contribución: Investigación ya publicada [1]

I. INTRODUCTION

En este trabajo se describe *Biblio-US17* [1], un conjunto de datos público diseñado para evaluar sistemas de detección de intrusiones basada en anomalías (AIDS) en servicios web. Los AIDS constituyen un área de investigación fundamental para identificar ataques desconocidos o emergentes. Por otra parte, los ataques basados en web representan un porcentaje significativo de los ciberataques en la actualidad. Sin embargo, la investigación en detección de intrusiones web ha estado históricamente limitada por la disponibilidad de datasets adecuados [2]. Gran parte de los conjuntos de datos existentes son sintéticos, con escasa variabilidad, con proporciones artificiales de ataques y con patrones obsoletos [3]. Además, muchos carecen de un etiquetado adecuado o se basan en tráfico simulado que no refleja la complejidad del comportamiento real de usuarios y atacantes.

Biblio US17 aborda estas limitaciones proporcionando un dataset operativo, etiquetado con varios niveles de confianza, y suficientemente voluminoso para estudiar fenómenos como la deriva temporal o el entrenamiento insuficiente en modelos de aprendizaje automático. El propósito principal es ofrecer




Figura 1. Fases en la adquisición y etiquetado de Biblio-US17

un recurso sólido para la evaluación de técnicas de detección de anomalías basadas en URIs.

Está compuesto por registros obtenidos a partir de las trazas del servicio HTTP de la Biblioteca de la Univ. de Sevilla entre el 1/1/2017 y el 17/7/2017. El servidor considerado utiliza tecnologías contemporáneas —*Drupal CMS* (v7.96) sobre *Apache web server* (v2.2)— proporcionando un servicio flexible con alta complejidad y variabilidad que es accedido por un elevado número de usuarios. El conjunto de datos incluye etiquetas que establecen una *ground truth*, distinguiendo entre solicitudes legítimas y ataques basados en URI.

II. METODOLOGÍA DE ADQUISICIÓN Y PROCESAMIENTO

El conjunto de datos se obtuvo a partir de los registros de un servidor web. Debido a las regulaciones de privacidad, los operadores solo proporcionaron algunos campos de las trazas, omitiendo valores como marcas de tiempo, IPs y el campo *referer*. Estos registros han sido preprocesados y etiquetados siguiendo la metodología propuesta en [4], que considera varias fases (Fig. 1), como se describe a continuación.

II-A. Preprocesado y acondicionamiento

El preprocesado y acondicionamiento tiene como objetivo preparar los datos, eliminando los registros inválidos, normalizando su contenido y posibilitando la indexación y

referencia. De esta forma, a lo largo de 198 días se recopilieron 47.902.323 registros, de los cuales se mantuvieron 47.402.907 entradas válidas. Cada uno de ellos ha sido indexado mediante una etiqueta (RID) que codifica fecha y orden de llegada.

Cada registro contiene, además del RID, el método, la URI completa solicitada, la versión del protocolo, el código y el tamaño de la respuesta.

Debido a la presencia de datos sensibles (como identificadores de usuario, rutas internas, etc.), se aplicó un riguroso proceso de anonimización supervisado por personal legal y de seguridad. Se sustituyeron cadenas sensibles mediante técnicas de preservación de patrones que mantienen características estadísticas relevantes para la detección de anomalías. En total, solo el 5,4 % de las cadenas del URI fueron modificadas, minimizando el impacto sobre la utilidad del dataset.

II-B. Etiquetado

La clasificación de los registros se llevó a cabo mediante una metodología secuencial [4]:

- S1 – Detección de ataques conocidos: Se utilizaron firmas de Snort, Nemesida y ModSecurity (CRS) para identificar URIs potencialmente maliciosas.
- S2 – Validación supervisada: Un equipo especializado revisó cada alerta, clasificando los verdaderos positivos en ataques LVL1 (indudables) o LVL2 (dependientes del contexto). Asimismo, se identificaron y etiquetaron los falsos positivos.
- S3 – Inspección del vocabulario de los URI: Mediante la segmentación de URIs en *path*, *key* y *value*, y el análisis de más de 80.000 cadenas únicas, se identificó un número significativo de ataques adicionales. Esta fase permitió además descubrir ataques de codificación –uso incorrecto de *percent encoding*– (LVL3) y patrones de escaneo y ráfagas de peticiones (LVL4). También se identificaron URIs fuera de especificación (OOS1–OOS4).

Los resultados y etiquetas obtenidos en cada fase se incluyen en el dataset¹, estableciéndose 4 conjuntos de datos (véase la Fig. 1):

- el dataset original (RAW) –preprocesado y anonimizado–,
- un conjunto de ataques (ATAQUES) etiquetados con diferentes niveles,
- un conjunto de URIs que no siguen la especificación del protocolo (OOS), también etiquetados según la anomalía identificada, y, finalmente,
- un conjunto de registros considerados legítimos.

De esta forma, el resultado final no sólo contiene peticiones limpias sino que también incluye 327.906 ataques indubitados (LVL1) adquiridos en un escenario real, además de otras categorías útiles para investigación en detección.

III. DESCRIPCIÓN DEL DATASET

El dataset se proporciona organizado en varios bloques cada uno compuesto por archivos de texto y organizados en directorios (Tabla I). Cada línea en estos archivos se refiere a un registro indexado mediante un identificador de registro RID que lo relaciona con el registro original en las trazas.

¹El dataset y una descripción detallada del mismo están disponibles en <https://idus.us.es/handle/11441/148254>

Tabla I
DIRECTORIOS (BLOQUES) DE BIBLIO-US17.

Dir	Contenido
RAW	Dataset completo: todos los registros válidos tras anonimización
LABELS	Etiquetas asignadas durante la sanitización, indexadas por [RID]
SID	Alertas generadas por los IDS, indexadas por [RID]
CLEAN	Registros limpios indexados por [RID]
ATTACK	Registros ataques indubitados (LVL1)
PARTITIONS	Particionado sugerido para peticiones limpias para su uso en entrenamiento/test/validación
AUX	Archivos auxiliares (reglas, scripts, herramientas)

Tabla II
ETIQUETAS ASIGNADAS (POR TIPO)

Clase	Label	All	CR<300
Ataques	LVL1	327 906	1 148
	LVL2	10 634	617
	LVL3	5 515	3 442
	LVL4	4 310	0
	TOTAL	348 365	5207
FP	FP	9222	8184
OOS	OOS1	169	98
	OOS2	2 021	1 735
	OOS3	6 567	6 178
	OOS4	1 595	1 106
	TOTAL	10 352	9 117
Limpios		42473128	

Como se muestra en la Tabla I, el conjunto de datos distribuido incluye, además del dataset limpio, listas codificadas de las etiquetas/categorías asignadas a cada registro, incluyendo los identificadores (SID) de las firmas activadas, las categorías tras supervisión, etc. Esto permite rastrear cada decisión de clasificación y, potencialmente, re-etiquetar los registros.

En la Tabla II se muestra el número de registros etiquetados en cada categoría (LABELS) así como el número de registros considerados finalmente limpios.

IV. CONCLUSIONES

Este artículo presenta una visión general del conjunto de datos Biblio-US17. El conjunto de datos es notable por derivarse de operaciones reales de servidores, abarcando un volumen considerable de datos durante un periodo de tiempo extenso. Incluye ataques reales en proporciones auténticas.

El conjunto de datos está disponible públicamente y se espera que sirva de referencia para la evaluación de los A-IDS en el contexto de ataques basados en URI.

AGRADECIMIENTOS

Ayudas PID2024-155581OB-C21 y PID2020-115199RB-I00 financiadas por MICIU/AEI/10.13039/501100011033/FEDER/UE.

REFERENCIAS

- [1] J. Díaz-Verdejo, R. Estepa, A. Estepa, J. Muñoz-Calle, G. Madinabeitia: "Building a large, realistic and labeled HTTP URI dataset for anomaly-based intrusion detection systems: Biblio-US17". *Cybersecurity*, 8, 1 -21, 2025.
- [2] M. Ring, S. Wunderlich, D. Scheuring, D. Landes, A. Hotho: "A survey of network-based intrusion detection data sets". *Computers & Security*, 86, 147-167, 2019.
- [3] R. Sommer, V. Paxson: "Outside the Closed World: On using Machine Learning for Network Intrusion Detection". *Proc. 2010 IEEE symposium on security and privacy*, 305–316, 2010.
- [4] J.E. Díaz-Verdejo, A. Estepa, R. Estepa, G. Madinabeitia, F.J. Muñoz-Calle: "A methodology for conducting efficient sanitization of HTTP training datasets". *Future Generation Computer Systems*, 109, 67-82, 2020.

Sesión de Formación 2 - Plataformas y entornos prácticos de aprendizaje

Laboratorio docente de ciberseguridad: diseño, instrumentación y despliegue para prácticas y retos técnicos

Joaquín Sierra Granados
UCLM

Ciudad Real, España
joaquin.sierra@uclm.es

José Luis Ruíz Catalán
UCLM

Ciudad Real, España
jose-luis.ruiz@uclm.es

Eugenio Romero Ciudad
UCLM

Ciudad Real, España
eugenio.romero@uclm.es

Ángel Suárez-Bárcena
UCLM

Ciudad Real, España
angel.sbarcena@uclm.es

Antonio Santos-Olmo
UCLM

Ciudad Real, España
antonio.santos@uclm.es

Eduardo Fernández-Medina Patón
UCLM

Ciudad Real, España
eduardo.fdezmedina@uclm.es

Resumen—La formación inicial en ciberseguridad en titulaciones de Informática suele apoyarse en enfoques predominantemente teóricos y con exposición limitada a entornos instrumentados y realistas, lo que dificulta el desarrollo temprano de habilidades operativas. Este trabajo presenta el diseño e implementación de un laboratorio docente de ciberseguridad concebido como una plataforma técnica de experimentación controlada, con aislamiento de red, control de alcance y mecanismos de observabilidad que permiten relacionar acciones de análisis con evidencias verificables. La infraestructura integra escenarios reproducibles, servicios simulados y un conjunto de herramientas para reconocimiento, evaluación de exposición y análisis de vulnerabilidades, además de paneles de monitorización para inspección de tráfico y eventos. Como caso de referencia se utiliza un entorno Smart Home, empleado como banco de pruebas IoT para actividades sobre arquitectura de red, exposición de servicios, análisis de evidencias y verificación de mitigaciones. El laboratorio se opera mediante prácticas guiadas, talleres y retos colaborativos (CTF/Hack&Win), apoyados por un club que facilita continuidad y mentorización entre pares. Los resultados observados, a partir de indicadores de uso y participación, muestran una adopción sostenida del entorno y un incremento del alcance de las actividades. La contribución principal es un modelo de laboratorio replicable y técnicamente instrumentado para soportar formación práctica en ciberseguridad mediante experimentación segura y reproducible.

Index Terms—Ciberseguridad, Laboratorio docente, Aprendizaje activo, Aprendizaje experiencial, Entornos simulados, Formación práctica, Enseñanza universitaria de la Informática, Competencias en ciberseguridad

Tipo de contribución: *Formación e innovación educativa*

I. INTRODUCCIÓN

La educación en ciberseguridad en las universidades españolas, particularmente en los grados de Ingeniería Informática, se enfrenta al reto de alinear la formación académica con una realidad profesional marcada por la rápida evolución tecnológica y de amenazas. Aunque la ciberseguridad se reconoce como una competencia transversal, su integración temprana en el currículo suele ser limitada y predominantemente teórica, causando que la materia sea percibida como poco atractiva por los estudiantes en esta etapa inicial, lo que dificulta la comprensión y reduce la motivación en los primeros cursos. En este contexto, la ausencia de un entorno

instrumentado dificulta que el alumnado relacione los conceptos iniciales con comportamientos observables sobre sistemas reales.

Para abordar estas limitaciones, este trabajo presenta una experiencia replicable basada en el diseño y despliegue de un laboratorio de ciberseguridad promovido desde el Grupo de Investigación en Seguridad y Auditoría (GSyA) de la Universidad de Castilla-La Mancha, concebido como una plataforma técnica de experimentación controlada. La propuesta combina escenarios tecnológicos reproducibles, prácticas supervisadas y actividades de mayor intensidad (talleres, club y retos tipo CTF/Hack&Win), con el objetivo de reducir la abstracción y facilitar la transición hacia habilidades operativas. Desde una perspectiva técnica orientada a docencia el foco se sitúa en el laboratorio como herramienta: aislamiento y control de alcance para experimentar de forma segura, observabilidad mediante monitorización de tráfico y eventos, y consistencia del escenario para sostener progresión entre sesiones. Como caso de referencia, se utiliza un entorno Smart Home que actúa como banco de pruebas IoT para trabajar arquitectura de red, exposición de servicios, análisis de evidencias y verificación de mitigaciones sobre un sistema tangible.

La literatura reciente respalda que la ciberseguridad, por su naturaleza aplicada, requiere entornos de aprendizaje orientados a la práctica para lograr resultados educativos efectivos. La evidencia empírica muestra que los laboratorios basados en sistemas y redes realistas mejoran significativamente el compromiso, la comprensión conceptual y la adquisición de destrezas frente a enfoques puramente teóricos [1], [2]. En particular, los entornos interactivos de entrenamiento favorecen la interiorización de conceptos complejos, permiten explorar dinámicas de ataque-defensa y facilitan el aprendizaje a partir de errores de configuración dentro de un marco controlado [1].

Más allá de las actividades aisladas en laboratorio, trabajos previos subrayan la conveniencia de modelos estructurados que integren aprendizaje experiencial, colaboración y mentorización. Revisiones sobre marcos educativos en ciberseguridad identifican plataformas prácticas, retos gamificados y comunidades de aprendizaje con apoyo entre iguales co-

mo factores clave para sostener la motivación y desarrollar competencias profesionales tempranas, señalando al mismo tiempo que numerosos programas carecen aún de diseños coherentes y replicables que integren estos elementos de manera efectiva [3]. De forma complementaria, investigaciones sobre educación temprana en ciberseguridad muestran que la exposición inicial a amenazas realistas y tecnologías interactivas influye positivamente en el interés del alumnado y en su preparación para formación avanzada [4], mientras que los enfoques de laboratorio basados en problemas pueden superar ejercicios excesivamente procedimentales al promover razonamiento analítico, autonomía y compromiso sostenido [5]. En conjunto, estas evidencias aportan un fundamento sólido para propuestas basadas en laboratorios instrumentados y escenarios reproducibles como el que se presenta en este trabajo.

Además, la propuesta se alinea con el compromiso institucional de la Universidad de Castilla-La Mancha con el refuerzo de la formación en ciberseguridad. Tal y como se ha señalado en trabajos previos sobre el Grado en Ingeniería Informática en la UCLM, se han identificado limitaciones estructurales en la formación temprana y la necesidad de mecanismos complementarios para mejorar la adquisición de competencias en ciberseguridad [6]. En este marco, el laboratorio presentado actúa como habilitador práctico, reforzando áreas competenciales y proporcionando un complemento aplicado y técnicamente instrumentado a la estrategia curricular promovida por la institución.

El resto del artículo se organiza como sigue. La Sección 2 presenta los requisitos y objetivos del laboratorio, junto con el contexto docente y las competencias objetivo. La Sección 3 describe la arquitectura y el diseño del laboratorio, incluyendo los mecanismos de aislamiento, control de alcance y observabilidad. La Sección 4 detalla los escenarios y el banco de pruebas, tomando como referencia el caso Smart Home y su progresión de actividades. La Sección 5 expone el procedimiento de operación y uso docente del entorno, así como el enfoque de evaluación y los criterios de transferencia. La Sección 6 recoge los resultados observados y su discusión, incorporando las limitaciones y amenazas a la validez. Finalmente, la Sección 7 presenta las conclusiones y el trabajo futuro.

II. REQUISITOS Y OBJETIVOS DEL LABORATORIO

La propuesta se sitúa en el contexto de titulaciones de Ingeniería Informática, donde la ciberseguridad puede aparecer de forma distribuida en varias materias o concentrada en asignaturas específicas de cursos avanzados. En ambos casos, existe un espacio de mejora cuando se pretende introducir tempranamente competencias de seguridad sin disponer de un “anclaje” tecnológico instrumentado que permita observar con claridad el impacto de configuraciones, decisiones de diseño o errores de implementación. Este tipo de integración transversal y progresiva ha sido abordado mediante estrategias de “infusión” de módulos de ciberseguridad en asignaturas troncales, precisamente para reducir la desconexión entre contenidos y práctica en etapas tempranas [7], y se reconoce además como un reto recurrente en revisiones sobre diseño de actividades y currículos en ciberseguridad [8]. Desde una perspectiva alineada con JNIC, el anclaje se materializa como

un laboratorio que soporte ejecución segura y reproducible de tareas técnicas, y que permita capturar evidencias observables (p. ej., tráfico, eventos y estados) para relacionar acciones con efectos.

II-A. Necesidad y requisitos funcionales

La formación inicial en ciberseguridad adolece de una brecha entre la explicación conceptual y la adquisición de competencias aplicadas, especialmente al comienzo del grado, cuando el alumnado aún no dispone de base suficiente para interpretar fenómenos reales de exposición, tráfico o incidentes. Este desajuste favorece aprendizajes memorísticos (terminología y tipologías) en detrimento del razonamiento causal y de la capacidad para proponer mitigaciones realistas. Para abordar esta limitación, la propuesta se apoya en un laboratorio instrumentado que satisface tres requisitos funcionales: aislamiento y control de alcance, para experimentar con herramientas ofensivas/defensivas sin impacto externo; observabilidad, para relacionar acciones con evidencias técnicas durante la sesión; y reproducibilidad, para garantizar consistencia del escenario entre prácticas y retos y permitir comparar el “antes” y el “después” de las medidas aplicadas [8].

II-B. Competencias objetivo

La intervención se orienta al desarrollo de competencias técnicas y transversales verificables sobre el entorno. En el plano técnico, se pretende que el alumnado identifique superficies de ataque, realice evaluaciones básicas de exposición y vulnerabilidades con herramientas estándar, interprete evidencias de tráfico y registros y proponga contramedidas justificadas. En el plano transversal, se refuerzan el trabajo colaborativo, la comunicación técnica y el uso ético y responsable de herramientas, incluyendo control de alcance y documentación de evidencias. Estas competencias se alinean con marcos de referencia en ciberseguridad [10] y con recomendaciones curriculares basadas en resultados en informática [9].

II-C. Resultados de aprendizaje y alineación con evaluación

Los resultados de aprendizaje se definen de manera observable para facilitar su evaluación mediante evidencias técnicas generadas durante la práctica. Se pretende que el alumnado pueda modelar un sistema identificando componentes, flujos y dependencias y, a partir de ello, enumerar su superficie de ataque. Asimismo, se espera que pueda ejecutar actividades de reconocimiento y análisis en un entorno controlado, interpretar evidencias y formular hipótesis de vulnerabilidad, validándolas de forma justificada. Finalmente, el alumnado debe ser capaz de proponer mitigaciones factibles, argumentarlas con base técnica y documentar resultados con rigor, presentando recomendaciones comprensibles y accionables, incluyendo evidencias mínimas que permitan trazabilidad y revisión. Este planteamiento es coherente con enfoques actuales de diseño curricular y evaluación que enfatizan la especificación explícita de resultados y su alineación con actividades y evidencias observables [9], así como con marcos de diseño instruccional que recomiendan articular objetivos, actividades y evaluación de forma integrada para asegurar coherencia pedagógica [11].




Figura 1. Diseño del laboratorio.

III. ARQUITECTURA Y DISEÑO DEL LABORATORIO

El laboratorio se concibe como una plataforma técnica de experimentación controlada orientada a convertir conceptos abstractos en evidencias observables. Su arquitectura persigue tres objetivos: habilitar escenarios reproducibles sobre los que el alumnado pueda ejecutar acciones acotadas, garantizar seguridad operativa mediante aislamiento y control de alcance, y maximizar la observabilidad para relacionar acciones con efectos medibles en tráfico, eventos y estados. Este enfoque sostiene un flujo de trabajo en el que el alumnado establece una línea base, ejecuta acciones controladas, interpreta evidencias y verifica mitigaciones sobre el propio escenario.

El diseño del espacio combina demostración, práctica supervisada y puesta en común. Los puestos de trabajo y la zona central del escenario Smart Home permiten realizar análisis, configuraciones y verificaciones sobre un sistema tangible mientras el profesorado supervisa el cumplimiento del alcance permitido (Fig. 1). Esta organización orienta la sesión hacia objetivos técnicos concretos y favorece que la intervención docente se centre en la interpretación de evidencias.

La infraestructura de soporte facilita mantener escenarios consistentes entre sesiones, aprovisionar servicios y recuperar estados de forma eficiente, asegurando repetibilidad, comparabilidad y escalado hacia actividades de mayor intensidad, como retos Hack&Win.

Un aspecto diferencial del diseño es la orientación a la observabilidad del fenómeno de seguridad, incorporada como parte del propio proceso formativo. El laboratorio dispone de pantallas que muestran paneles de control de los proyectos y escenarios desplegados, así como visualizaciones de estado y métricas operativas; adicionalmente, se emplean herramientas de análisis como Wireshark para la captura e inspección de tráfico asociado a las prácticas, facilitando el análisis detallado de comunicaciones y la identificación de patrones anómalos. Como complemento contextual, se proyectan mapas globales de ciberataques (p. ej., paneles tipo Kaspersky) que permiten situar la actividad del laboratorio en un marco de amenazas real y actual.




Figura 2. Dispositivos del laboratorio de GSyA

Tecnológicamente, la arquitectura integra recursos de instrumentación y experimentación segura. El equipamiento disponible permite trabajar con dispositivos heterogéneos, realizar reconocimiento, evaluar exposición y ejecutar análisis básicos de vulnerabilidades en un entorno acotado (Fig. 2).




Figura 3. Monitorización de los diferentes elementos del laboratorio GSyA

En conjunto, el uso de estas pantallas y paneles de monitorización proporciona visibilidad en tiempo real del estado del escenario, del comportamiento de red y de eventos relevantes, transformando señales técnicas en evidencias interpretables durante la sesión (Fig. 3). Esta instrumentación habilita retroalimentación inmediata y soporta discusiones de causa-efecto, ya que el alumnado puede contrastar cómo acciones sobre el

sistema se reflejan en trazas observables (por ejemplo, tráfico, eventos o métricas). Desde el punto de vista docente, esta capa de observabilidad permite evaluar no solo si una tarea se completa, sino si el alumnado sabe justificar técnicamente lo observado y proponer medidas correctivas verificables.

El diseño incorpora un componente colaborativo orientado a la comunicación y verificación técnica. Se dispone de un espacio de discusión con apoyo (pizarra y pantallas) que permite cerrar cada sesión con una puesta en común estructurada y basada en evidencias, donde el alumnado expone resultados, contrasta enfoques y compara estrategias seguidas durante la práctica. En este contexto, se analizan de forma conjunta aspectos como el impacto de las acciones realizadas, los riesgos identificados y la efectividad de las mitigaciones propuestas, fomentando el razonamiento crítico y el aprendizaje entre iguales. Esta fase consolida el aprendizaje al exigir explicar y justificar técnicamente los resultados, alineándolo con prácticas profesionales. En conjunto, el laboratorio combina experimentación segura, observabilidad y supervisión, y soporta actividades de distinta intensidad (talleres, club y *Hack&Win*) sobre un mismo entorno técnico, manteniendo coherencia entre práctica, análisis y discusión.

III-A. Requisitos mínimos de despliegue

Para replicar un laboratorio de ciberseguridad seguro como el descrito, se requieren mínimos orientados a aislamiento, control de alcance y observabilidad. Es necesario disponer de una red segmentada (por ejemplo, VLANs) y un elemento perimetral (router/firewall) para aplicar filtrado y evitar impacto sobre redes de producción. Asimismo, se requiere al menos un host de virtualización o equipo capaz de ejecutar escenarios reproducibles (máquinas virtuales y/o contenedores) y almacenar imágenes/snapshots para restaurar el estado entre sesiones (como referencia mínima, CPU multinúcleo, 32 GB de RAM y SSD, escalable según carga). Por último, debe existir capacidad de captura y visualización de evidencias durante la práctica (p.ej., Wireshark y dashboards en pantalla) y un procedimiento de recuperación del escenario (snapshots/plantillas/scripts) que garantice repetibilidad y consistencia en prácticas y retos.

IV. ESCENARIOS Y BANCO DE PRUEBAS

El laboratorio se apoya en un conjunto de escenarios reproducibles que actúan como banco de pruebas para prácticas y retos, permitiendo ejecutar tareas de ciberseguridad sobre sistemas acotados e instrumentados. Como escenario de referencia se utiliza un entorno de hogar inteligente (Fig. 4), seleccionado por su capacidad para concentrar, en una topología manejable, heterogeneidad típica de IoT y de red y habilitar análisis end-to-end. En particular, el escenario integra dispositivos habituales en un hogar conectado, como cámaras IP, bombillas inteligentes, enchufes inteligentes, asistentes de voz (p. ej., Alexa) y sensores de movimiento, junto con la red local y los servicios de control asociados. Frente a entornos corporativos complejos o poco accesibles para alumnado en etapas tempranas, el Smart Home ofrece un sistema tangible donde es posible observar de forma directa el impacto de configuraciones, exposición de servicios y medidas de mitigación, con control del alcance y de los estados del escenario.



Figura 4. Smart Home del laboratorio GSyA

Desde una perspectiva técnica, la elección del Smart Home responde a criterios de realismo, integración y control. En primer lugar, proporciona un contexto en el que vectores de ataque habituales y consecuencias operativas son interpretables de forma inmediata (por ejemplo, credenciales por defecto, servicios expuestos o configuraciones inseguras). En segundo lugar, permite integrar tecnologías y capas que habitualmente se tratan por separado, combinando conectividad inalámbrica (por ejemplo, Wi-Fi y, cuando aplica, Zigbee/Bluetooth), servicios de red y flujos hacia aplicaciones o servicios externos, obligando a abordar la seguridad como propiedad sistémica. En tercer lugar, habilita escalabilidad controlada: el escenario es suficientemente realista como para representar problemas contemporáneos de IoT (actualización limitada, servicios innecesarios, configuraciones por defecto), pero permanece acotado para permitir experimentación segura, supervisada y repetible, con control explícito del alcance y de los estados del sistema.

En este marco, el Smart Home se utiliza como banco de pruebas donde arquitectura de red, exposición, monitorización y respuesta básica se traducen en evidencias observables (tráfico, eventos y estados) durante la sesión. El objetivo no es solo ejecutar herramientas, sino seguir un flujo técnico consistente: establecer una línea base, enumerar superficie de ataque, validar hipótesis con evidencias y aplicar y verificar mitigaciones. Este enfoque centra la actividad en el ciclo completo de análisis y verificación y facilita la comparación entre sesiones al mantener consistencia del escenario y de la observación.

IV-A. Justificación técnica del escenario

El valor del ecosistema Smart Home reside en su capacidad para integrar, en un único contexto, dominios que aparecen fragmentados en el plan de estudios: redes, sistemas embebidos, protocolos inalámbricos, servicios y aplicaciones. Esta convergencia permite introducir una visión holística de seguridad, donde el análisis incluye comunicaciones, configuraciones, dependencias y cadena de control, y no se limita al “dispositivo vulnerable”. Además, el escenario facilita el análisis de trade-offs habituales en IoT (funcionalidad frente a exposición, usabilidad frente a autenticación, disponibilidad frente a monitorización), permitiendo discutir mitigaciones realistas y su validación mediante evidencias observables. Desde el punto de vista operativo, un escenario único y estable reduce el coste de preparación y permite mantener consistencia técnica entre sesiones, habilitando progresión en complejidad sin cambiar el contexto.

IV-B. *Contenidos y conceptos integrados*

El escenario permite abordar de forma aplicada contenidos transversales relacionados con seguridad ofensiva y defensiva en entornos IoT. En el plano de infraestructura, se trabajan arquitectura de red, segmentación y seguridad en comunicaciones, incluyendo consideraciones sobre conectividad inalámbrica y aislamiento. En análisis de riesgos, se introduce modelado de amenazas y enumeración de superficie de ataque en sistemas heterogéneos, con atención a componentes con recursos limitados y servicios auxiliares. En auditoría técnica, se incorporan técnicas de reconocimiento y evaluación de exposición, uso de herramientas de escaneo, verificación de configuraciones y explotación controlada cuando procede, siempre bajo supervisión y con alcance definido. En gestión de identidad y acceso, se analizan mecanismos de autenticación y autorización, emparejamiento de dispositivos y buenas prácticas de endurecimiento. En defensa operativa, se trabajan monitorización, inspección de tráfico y análisis de registros para detección temprana de eventos, así como la validación de contramedidas mediante comparación antes/después sobre el propio escenario.

IV-C. *Secuencia técnica de actividades*

La experiencia se organiza como una progresión de complejidad creciente que preserva seguridad y reproducibilidad. En una primera fase, se realiza exploración guiada orientada a construir una línea base: identificación de componentes, documentación de flujos y caracterización del comportamiento normal del sistema, incluyendo recopilación de evidencias (tráfico/eventos) para detectar desviaciones. En una segunda fase, se lleva a cabo experimentación controlada y supervisada: reconocimiento activo, análisis de exposición, inspección de tráfico y validación de hipótesis, incluyendo cuando aplica vulnerabilidades introducidas de forma deliberada o configuraciones inseguras controladas. En esta fase, el objetivo es observar el efecto de acciones técnicas sobre evidencias verificables y contrastar medidas de mitigación mediante comparación antes/después sobre el propio escenario. En una tercera fase, la práctica culmina con retos con objetivos concretos (por ejemplo, CTF/Hack&Win), donde se requiere combinar técnicas y evidencias para alcanzar un objetivo definido, documentar resultados y justificar mitigaciones, cerrando con una discusión técnica orientada a impacto, riesgo y medidas correctivas verificables. Los talleres temáticos no vinculados al escenario IoT (p. ej., vulnerabilidades web como inyección SQL) se tratan de forma independiente, tal y como se describe en la Sección V-A.

IV-D. *Seguridad, ética y control*

El despliegue se concibe como un entorno que enseña seguridad operativa de forma activa. El aislamiento de red se utiliza como requisito técnico y, a la vez, como contenido formativo: segmentación, control de rutas y filtrado perimetral permiten contener la experimentación y evitar impactos fuera del entorno, ilustrando defensa en profundidad. La dimensión ética se gestiona mediante control explícito de alcance y normas de uso responsable, de forma que la ejecución de técnicas ofensivas se limita a activos autorizados y a objetivos definidos. Finalmente, la monitorización se emplea como mecanismo de trazabilidad y retroalimentación: la observación

de tráfico, eventos y estados permite intervenir durante la sesión, discutir errores frecuentes y transformar incidentes operativos en oportunidades de aprendizaje sobre detección, contención y respuesta.

V. OPERACIÓN Y USO DOCENTE DEL ENTORNO

En esta sección se describe cómo se opera el laboratorio como entorno técnico de experimentación controlada para prácticas de ciberseguridad. Se detallan los modos de uso (talleres, club y retos), el flujo operativo de una sesión (objetivo, alcance, ejecución, evidencias y verificación) y el enfoque de evaluación utilizado para observar adopción del entorno y desempeño técnico a partir de evidencias generadas durante la práctica.

V-A. *Actividades de aprendizaje y dinámicas de grupo*

La estrategia se fundamenta en un modelo híbrido que combina docencia reglada con aprendizaje no formal, utilizando el laboratorio como entorno común para prácticas guiadas y retos de mayor intensidad. En el aula-laboratorio, la sesión se estructura en una fase inicial de preparación donde se define el objetivo técnico, el alcance permitido (activos autorizados, límites de red y restricciones de herramientas) y el criterio de verificación, seguida de una fase práctica supervisada en la que el alumnado ejecuta tareas sobre escenarios reproducibles. Durante esta fase se enfatiza la generación y conservación de evidencias (por ejemplo, resultados de herramientas, capturas y trazas observables) para justificar decisiones técnicas. La sesión se cierra con una puesta en común orientada a contraste de estrategias, discusión de causas y efectos observados y verificación de mitigaciones aplicadas sobre el propio escenario. Este enfoque permite alternar ejecución práctica con discusión basada en evidencias, facilitando la identificación de errores frecuentes y la corrección temprana bajo supervisión.

Además del banco de pruebas principal basado en Smart Home, el laboratorio acoge talleres temáticos independientes orientados a vulnerabilidades específicas no ligadas al escenario IoT. Por ejemplo, se realizan sesiones prácticas centradas en vulnerabilidades web comunes (p. ej., inyección SQL) sobre aplicaciones deliberadamente vulnerables desplegadas en el propio entorno controlado, con el objetivo de entrenar detección, explotación controlada y aplicación de contramedidas (p. ej., validación de entradas y parametrización), manteniendo el mismo marco de aislamiento, control de alcance y monitorización del laboratorio. Estas actividades complementarias permiten cubrir técnicas transversales y diversificar el entrenamiento sin introducir ambigüedad respecto al rol del Smart Home como escenario de referencia.

Las dinámicas gamificadas, en particular los retos tipo Capture The Flag (CTF) y las sesiones "Hack&Win", se utilizan como mecanismo de consolidación técnica al introducir objetivos explícitos, retroalimentación inmediata y un componente de progreso (puntuación o logros) que sostiene la implicación durante la actividad. Estos eventos fuerzan a integrar procedimientos de reconocimiento, análisis de exposición, interpretación de evidencias y validación de acciones bajo restricciones de tiempo, lo que aproxima la actividad a condiciones operativas. Asimismo, promueven aprendizaje entre iguales al desarrollarse en equipos o con interacción continuada entre participantes. Como extensión, el Club de

Ciberseguridad institucionalizado aporta continuidad fuera del horario lectivo y habilita un esquema de mentorización en el que alumnado de cursos superiores apoya a participantes noveles en procedimientos, documentación y verificación de evidencias, contribuyendo a la sostenibilidad del modelo y al uso recurrente del laboratorio.

V-B. Integración en docencia reglada

Además de talleres, club y retos, el laboratorio se emplea también en docencia reglada en varias asignaturas: en primer curso, asignaturas como *Álgebra y Matemática Discreta* con una práctica de criptografía asimétrica; en tercer curso, *Diseño de Software* con contenidos de diseño software seguro y securización de bases de datos; y en cuarto curso, donde varias asignaturas como *Seguridad en Sistemas Software*, *Seguridad en Redes* o *Seguridad en Sistemas Informáticos* con ejercicios de securización de redes y endurecimiento de sistemas y software, aplicación de estándares y recomendaciones (NIST, ISO 27001, OWASP...). Esta integración, junto con las actividades extracurriculares (charlas, conferencias y actividades del club de ciberseguridad), mantiene coherencia entre fundamentos y práctica y favorece la progresión del alumnado.

V-C. Evaluación del aprendizaje e indicadores de impacto

Para valorar la efectividad de la propuesta se ha definido un modelo de evaluación basado en indicadores de alcance/compromiso y en evidencias técnicas generadas durante las actividades. En la iteración actual, el análisis se apoya principalmente en métricas agregadas de participación y seguimiento docente, mientras que la recogida sistemática de evidencias individuales (por ejemplo, write-ups) y la aplicación de instrumentos pre/post se plantea como parte del trabajo futuro.

1. Indicadores de alcance y participación: Se monitoriza la evolución interanual de participación en las sesiones Hack&Win, así como el crecimiento del Club de Ciberseguridad y su porcentaje de participación. Adicionalmente, se registra la asistencia media a talleres como aproximación a la demanda formativa recurrente. Estos indicadores permiten caracterizar la adopción del entorno, su capacidad de atracción y la continuidad de la actividad alrededor del laboratorio.
2. Evidencias de competencia técnica: La evaluación prevista no se limita al resultado final (p.ej., obtención de un "flag"), sino que considera el proceso seguido y la capacidad de justificar decisiones a partir de evidencias. Para ello, se contempla la entrega de write-ups (informes técnicos) en los que el alumnado documente metodología, herramientas empleadas, evidencias observadas y mitigaciones propuestas, incluyendo cuando aplica la delimitación de alcance y el uso responsable de las técnicas. En la presente edición, esta evidencia no se ha recogido todavía de forma sistemática y se incorporará en futuras iteraciones para disponer de artefactos comparables entre cursos.
3. Percepción del estudiante: Como complemento, se contempla el uso de cuestionarios de satisfacción y auto-percepción (escala Likert) pre y post-intervención para estimar cambios en confianza percibida y utilidad de la experiencia. En esta fase inicial, dicha información se ha



Figura 5. Evolución del número de participantes en Hack&Win.

recogido de forma informal mediante retroalimentación durante talleres y actividades del club, y se plantea su sistematización en futuras ediciones para obtener medidas cuantificables y comparables.

V-D. Criterios de transferencia y replicabilidad

La experiencia se ha diseñado bajo principios de modularidad y reproducibilidad para facilitar su adopción en otros contextos docentes y técnicos. La portabilidad se apoya en el uso de virtualización y contenedores para encapsular servicios y componentes de los escenarios y desplegarlos sobre infraestructuras estándar de laboratorio, reduciendo dependencias específicas de hardware y simplificando el aprovisionamiento. Adicionalmente, se han definido procedimientos de operación orientados a mantener consistencia entre sesiones (preparación del escenario, verificación del estado inicial y recuperación controlada), lo que facilita repetir prácticas y comparar resultados. Por otro lado, se ha elaborado un repositorio de materiales que incluye guías de actividad, configuración base del entorno y referencias de verificación, de manera que docentes de áreas afines (p. ej., redes o sistemas) puedan integrar módulos de seguridad en sus asignaturas sin necesidad de ser especialistas, manteniendo coherencia en objetivos, alcance permitido y evidencias esperadas.

VI. RESULTADOS OBSERVADOS Y DISCUSIÓN

En esta sección se presentan los resultados derivados de la puesta en operación del laboratorio y se discuten desde una perspectiva orientada a la adopción del entorno y a su capacidad para sostener actividad técnica reproducible. Se consideran indicadores cuantitativos de uso (participación, asistencia y actividad) junto con observaciones cualitativas recogidas durante prácticas y retos, con el objetivo de valorar el laboratorio como plataforma técnica para formación práctica, su aplicabilidad y las principales limitaciones de la evidencia disponible.

VI-A. Participación y alcance

Los resultados cuantitativos se sintetizan en la Tabla I, con indicadores de Hack&Win, del Club de Ciberseguridad y de los talleres del laboratorio por curso académico. Hack&Win dispone de registros para todo el periodo analizado, mientras que los datos del club (miembros y porcentaje de participación) y la asistencia media a talleres comienzan en 24/25, coincidiendo con la creación del club como mecanismo de continuidad.

En términos de alcance, Hack&Win muestra crecimiento sostenido (Fig. 5), pasando de 25 participantes en 21/22 a 65 en 25/26 (incremento de 40 y crecimiento relativo aproximado del 160 %).

Tabla I
INDICADORES DE ALCANCE Y COMPROMISO (CURSOS ACADÉMICOS).

Indicador	21/22	22/23	23/24	24/25	25/26
Nº participantes Hack&Win	25	16	40	48	65
Nº miembros en el club de ciberseguridad	N/A	N/A	N/A	27	82
Nº participantes (media) en los talleres	N/A	N/A	N/A	22	55
% de participación del club	N/A	N/A	N/A	81,48 %	67,07 %




Figura 6. Número de miembros del club de ciberseguridad.



Figura 7. Asistencia media a talleres del laboratorio por curso.

De manera complementaria, el club crece en miembros (Fig. 6) y registra una participación del 81,48 % en 24/25 y del 67,07 % en 25/26; esta reducción relativa es compatible con la expansión de la base de miembros y una participación más puntual en perfiles heterogéneos, por lo que el indicador se interpreta como medida de actividad efectiva.

En el mismo periodo, la asistencia media a talleres (Fig. 7) aumenta de 22 a 55 estudiantes por sesión, reforzando el laboratorio como canal de entrenamiento técnico recurrente y la demanda de sesiones prácticas sobre escenarios consistentes.

Además de los indicadores de participación, se observaron resultados cualitativos vinculados al diseño del laboratorio y al uso del Smart Home como banco de pruebas: su continuidad entre sesiones facilita conectar reconocimiento, análisis de exposición, observación de tráfico/eventos y verificación de mitigaciones con componentes y flujos concretos, sosteniendo una progresión desde exploración guiada (línea base) a análisis supervisado (validación con evidencias) y retos con objetivos definidos, manteniendo coherencia entre talleres, club y dinámicas competitivas.

En conjunto, los indicadores y observaciones apuntan a

la consolidación de un ecosistema alrededor del laboratorio (Hack&Win como actividad de mayor escala y club/talleres como continuidad), favoreciendo participación sostenida y progresión hacia tareas de mayor complejidad.

La mayoría de participantes procede de 1.ª y 2.ª curso, con menor presencia de 3.ª y 4.ª, principalmente por la reciente consolidación del Club de Ciberseguridad y del programa de talleres; en cualquier caso, talleres, club y eventos tipo CTF/Hack&Win se plantean como iniciativas transversales abiertas a todo el grado, con niveles de dificultad ajustables.

VI-B. Evidencias cualitativas de aprendizaje

Dado que en esta iteración no se han incorporado instrumentos formales de medición del aprendizaje (por ejemplo, pre/post o rúbricas), las evidencias disponibles deben interpretarse principalmente como señales de continuidad y apropiación del flujo de trabajo técnico. Más allá del crecimiento nominal, el porcentaje de participación del club se mantuvo en valores altos en ambos cursos disponibles, lo que sugiere que la adhesión al club no fue únicamente nominal. Este patrón es consistente con el uso del club como espacio de práctica continuada, donde las actividades del laboratorio actúan como motor de interacción recurrente y permiten reforzar procedimientos de análisis y documentación técnica de manera progresiva.

VI-C. Retroalimentación del alumnado

La retroalimentación recogida de manera informal durante talleres y actividades del club fue mayoritariamente positiva, destacándose el valor de trabajar con sistemas realistas, la utilidad de la práctica para comprender conceptos y el efecto motivador de los retos. En particular, se valoró la posibilidad de observar evidencias (tráfico/eventos) asociadas a acciones concretas y de verificar mitigaciones sobre el propio escenario, lo que favorece discusiones técnicas orientadas a causa-efecto. En cuanto a los talleres impartidos en el laboratorio, la asistencia media alcanzó 55 estudiantes por sesión en 25/26 (Tabla I), lo que refuerza la interpretación del laboratorio como canal de formación práctica de alta demanda.

VI-D. Aplicabilidad y replicabilidad (transferencia)

Desde una perspectiva de transferencia, la experiencia resulta replicable si se preservan elementos esenciales del diseño: un escenario realista pero acotado que actúe como banco de pruebas, aislamiento técnico que garantice seguridad y control de alcance, una secuenciación progresiva que combine guía y autonomía, y materiales de apoyo que estructuren objetivos, alcance permitido y evidencias esperadas. Considerados conjuntamente, los indicadores de talleres, club y Hack&Win apuntan a un efecto de ecosistema: el laboratorio no solo soporta actividades puntuales, sino que facilita

continuidad formativa mediante un espacio comunitario y un itinerario de actividades de distinta intensidad. Aunque no se dispone todavía de métricas individuales de trazabilidad entre actividades, la evolución conjunta de participación sugiere consolidación del modelo.

VI-E. Limitaciones y amenazas a la validez

Las conclusiones deben interpretarse en el marco de una primera iteración centrada en valorar viabilidad y adopción. Por ello, los resultados reportados caracterizan principalmente indicadores de alcance y compromiso (participación, inscripción, asistencia e índice de actividad), sin medidas directas estandarizadas de aprendizaje o progreso competencial. Al tratarse de actividades voluntarias, existe posible autoselección, si bien se atenúa al considerar tendencias interanuales y la actividad efectiva del club. En futuras ediciones se incorporarán instrumentos ligeros (pre/post breves y rúbricas de evidencias o write-ups) para complementar estos indicadores con medidas más directas del aprendizaje y permitir comparaciones entre cursos.

VII. CONCLUSIONES Y TRABAJO FUTURO

Se ha presentado el diseño y puesta en operación de un laboratorio de ciberseguridad como plataforma técnica para formación práctica en grados de Ingeniería Informática. La contribución principal reside en la combinación de un entorno de experimentación controlada, una progresión estructurada de actividades y un banco de pruebas basado en Smart Home que aporta heterogeneidad IoT en un sistema acotado, instrumentable y reproducible. Este enfoque permite trabajar de forma integrada tareas de reconocimiento, análisis de exposición, observación de evidencias (tráfico, eventos y estados) y verificación de mitigaciones, reduciendo la distancia entre fundamentos teóricos y procedimientos técnicos operativos.

Los resultados disponibles, sustentados en indicadores de alcance y compromiso (evolución de participación en Hack&Win, crecimiento del club y su porcentaje de participación, y asistencia media a talleres), apuntan a una adopción sostenida del entorno y a la consolidación de un ecosistema de actividades alrededor del laboratorio. En conjunto, la experiencia se considera transferible a otros contextos siempre que se preserven elementos técnicos clave: aislamiento y control de alcance, consistencia del escenario entre sesiones, mecanismos de observabilidad para capturar evidencias, y disponibilidad de materiales que definan objetivos, evidencias esperadas y criterios de verificación, facilitando documentación técnica comparable.

Como trabajo futuro, se plantea reforzar el marco de evaluación con instrumentos ligeros pero sistemáticos que complementen los indicadores de participación con medidas directas de aprendizaje y desempeño. En particular, se incorporarán cuestionarios pre y post breves alineados con resultados de aprendizaje (por ejemplo, identificación de superficie de ataque, interpretación de evidencias y selección de mitigaciones), así como rúbricas para evaluar artefactos producidos por el alumnado (informes breves o write-ups) con criterios comparables entre ediciones. Adicionalmente, se ampliará el catálogo de escenarios y tecnologías para cubrir

amenazas y contextos diversos, se sistematizarán procedimientos de recuperación de estado para facilitar repetibilidad, y se mejorará la trazabilidad agregada entre actividades (talleres-club-Hack&Win) mediante registros mínimos que permitan estimar retención y recorridos formativos sin incrementar la carga del alumnado. Finalmente, se incrementará la integración transversal del laboratorio en asignaturas afines (redes, sistemas, IoT) para reforzar de forma continuada principios de security-by-design y competencias aplicadas a lo largo del currículo.

AGRADECIMIENTOS

Esta publicación no habría sido posible sin el apoyo de los siguientes proyectos: Di4SPDS (PCI2023145980-2), financiado por MCIN/AEI/10.13039/501100011033 y por la Unión Europea (programa CHIST-ERA); KOSMOS-UCLM (PID2024-155363OB-C44), financiado por MCIN/AEI/10.13039/501100011033/FEDER, UE; AURORA (SBPLY/24/180225/000074), financiado por la Consejería de Educación, Cultura y Deportes de la Junta de Comunidades de Castilla-La Mancha y por el Fondo Europeo de Desarrollo Regional (FEDER) (Programa Operativo de Castilla-La Mancha 2021–2027); RADAR (2025-GRIN-38447), financiado por FEDER; y la ayuda RED2024-154240-T, financiada por MICIU/AEI/10.13039/501100011033.

REFERENCIAS

- [1] V. Švábenský, J. Vykopal, P. Čeleda, K. Tkáčik y D. Popovič: "Student assessment in cybersecurity training automated by pattern mining and clustering", en *Education and Information Technologies*, vol. 27, n. 7, pp. 9231–9262, 2022.
- [2] B. K. Payne, L. Mayes, T. Paredes, E. Smith, H. Wu y C. Xin: "Applying High Impact Practices in an Interdisciplinary Cybersecurity Program", en *Journal of Cybersecurity Education, Research and Practice*, vol. 2020, n. 2, pp. 1–26, 2021.
- [3] M. Mukherjee, N. T. Le, Y.-W. Chow y W. Susilo: "Strategic Approaches to Cybersecurity Learning: A Study of Educational Models and Outcomes", en *Information*, vol. 15, n. 2, pp. 117, 2024.
- [4] A. J. Jerman Blažič y B. J. Jerman Blažič: "Teaching and learning cybersecurity for European youth by applying interactive technology and smart education", en *Education and Information Technologies*, vol. 30, n. 7, pp. 9093–9120, 2025.
- [5] Y. Deng, Z. Zeng, K. Jha y D. Huang: "Problem-Based Cybersecurity Lab with Knowledge Graph as Guidance", en *Journal of Artificial Intelligence and Technology*, vol. 2, n. 2, pp. 55–61, 2022.
- [6] A. Santos Olmo, D. García Rosado, L. E. Sánchez, C. Blanco Bueno, M. Á. Serrano y E. Fernández-Medina Patón: "Perspectiva de la Ciberseguridad en el Grado de Ingeniería Informática de la ESI en la UCLM", en *Actas de las XXIX Jornadas sobre la Enseñanza Universitaria de la Informática (JENUI)*, pp. 287–294, 2023.
- [7] U. Kannan y R. Swamidurai: "Integrating Cybersecurity Concepts Across Undergraduate Computer Science and Information Systems Curriculum", en *2021 ASEE Virtual Annual Conference Content Access*, pp. 1–9, 2021.
- [8] M. Ismail, N. Madathil, M. Alalawi, S. Alrabae, M. Al Bataineh, S. Bani Melhem y D. Mouheb: "Cybersecurity activities for education and curriculum design: A survey", en *Computers in Human Behavior Reports*, vol. 16, n. 1, pp. 100501, 2024.
- [9] A. Kumar et al.: "Computer Science Curricula 2023", en *Computer Science Curricula 2023*, 2024.
- [10] R. Petersen, D. Santos, M. C. Smith, K. A. Wetzel y G. Witte: "Workforce Framework for Cybersecurity (NICE Framework)", en *NIST Special Publication 800-181 Revision 1*, 2020.
- [11] J. Allison: "Devising a cyber security management module through integrated course design", en *Journal of Further and Higher Education*, vol. 47, n. 10, pp. 1389–1403, 2023.

CTF como Servicio: Una infraestructura reproducible y escalable para la formación en ciberseguridad

Carlos Jimeno Miguel
Universidad Pública de Navarra
Pamplona, España
carlos.jimeno@unavarra.es

Mikel Izal Azcárate
Universidad Pública de Navarra
Pamplona, España
mikel.izal@unavarra.es

Resumen—Las competiciones de tipo *Capture The Flag* (CTF) se han consolidado como una herramienta pedagógica de gran eficacia en la formación en ciberseguridad, al ofrecer a los estudiantes experiencia práctica en escenarios realistas de ataque y defensa. Sin embargo, la organización y el alojamiento de estos eventos requiere un esfuerzo de infraestructura considerable que con frecuencia limita su adopción en entornos académicos. En este artículo se presenta el diseño, el desarrollo iterativo y la evaluación de una plataforma CTF como Servicio (CaaS) construida sobre la virtualización *Proxmox*, haciendo uso de herramientas de Infraestructura como Código (IaC) como *Terraform* y *Ansible*, orquestación de contenedores mediante *Docker Swarm* y balanceo de carga con *HAProxy*. El sistema soporta tanto un flujo de trabajo centrado en el desarrollo, en el que los retos se despliegan automáticamente desde un repositorio *Git* mediante una *pipeline CI/CD*, como un flujo orientado al despliegue para el aprovisionamiento *ad-hoc* de infraestructura. Se describen las decisiones de diseño adoptadas, los problemas encontrados durante el desarrollo y las soluciones implementadas para lograr persistencia de sesiones, enrutamiento externo y replicabilidad de retos. La plataforma está diseñada para evolucionar hacia un servicio de alojamiento de CTF con potencial comercial, y se esbozan las líneas de trabajo futuro en escalado automático, integración de monitorización y estandarización del *frontend*.

Index Terms—CTF, formación en ciberseguridad, Infraestructura como Código, *Docker Swarm*, *Proxmox*, *Terraform*, *Ansible*, *pipeline CI/CD*

Tipo de contribución: Formación e innovación educativa

I. INTRODUCCIÓN

La creciente demanda de profesionales en ciberseguridad a nivel mundial ha intensificado el interés por enfoques didácticos innovadores que doten a los estudiantes de las competencias prácticas que exige la industria. La formación tradicional en el aula, si bien valiosa para la adquisición de conocimientos teóricos, resulta con frecuencia insuficiente para desarrollar las habilidades ofensivas y defensivas que caracterizan el perfil de un experto en seguridad. En respuesta a esta necesidad, las instituciones académicas y las organizaciones profesionales han adoptado de manera creciente formatos de competición gamificados como complemento a los planes de estudio formales.

Las competiciones *Capture The Flag* (CTF) representan uno de los formatos más eficaces para cultivar competencias en ciberseguridad. Un CTF es una competición de seguridad informática en la que los participantes deben resolver una serie de retos técnicos para obtener cadenas de texto secretas denominadas *flags*, cuya presentación en la plataforma de

la competición otorga puntos al equipo o individuo que las encuentra. Los CTF se organizan habitualmente en tres modalidades principales: el formato *jeopardy*, en el que los retos se presentan de forma independiente clasificados por categoría y dificultad; el formato *ataque-defensa*, en el que los equipos deben simultáneamente proteger sus propios sistemas y comprometer los de sus adversarios; y el formato *King of the Hill* (KotH), en el que los participantes compiten por tomar el control de una misma máquina o sistema y mantenerlo el mayor tiempo posible frente al resto de competidores, combinando habilidades ofensivas y defensivas en tiempo real. Al presentar a los participantes retos realistas y autocontenidos en áreas como ingeniería inversa, explotación web, criptografía, análisis forense y explotación de binarios, los CTF tienden puentes entre el conocimiento teórico y la destreza práctica. Su estructura lúdica fomenta la participación, estimula el aprendizaje autónomo y promueve el desarrollo de estrategias de resolución de problemas directamente aplicables a escenarios reales.

La Universidad Pública de Navarra (UPNA) mantiene un compromiso firme con el avance de la formación en ciberseguridad como parte de una estrategia institucional más amplia orientada a impulsar la innovación tecnológica y a apoyar el desarrollo de proyectos con potencial de transferencia comercial. Con financiación específica canalizada hacia iniciativas educativas e investigación aplicada, la universidad ha buscado activamente desarrollar infraestructura capaz de dar soporte a eventos CTF recurrentes para su comunidad estudiantil. Este esfuerzo refleja el reconocimiento de que la formación en ciberseguridad no es solo una prioridad académica, sino también un motor de desarrollo tecnológico regional y una vía hacia la empleabilidad cualificada.

Organizar y alojar un evento CTF es, sin embargo, una tarea técnicamente exigente. Configurar entornos aislados y reproducibles para cada reto, garantizar el acceso equitativo de todos los participantes, gestionar el escalado bajo carga concurrente y mantener una conectividad fiable constituyen desafíos operacionales de considerable envergadura. En entornos académicos con personal técnico limitado y recursos *hardware* restringidos, la carga operacional asociada al alojamiento de CTFs puede convertirse en una barrera que limita tanto la frecuencia como la calidad de dichos eventos.

Este artículo aborda este reto presentando el diseño y el desarrollo iterativo de una plataforma CTF como Servicio

construida sobre la infraestructura de virtualización *Proxmox* de la UPNA. Mediante la integración de herramientas IaC, orquestación de contenedores y una *pipeline CI/CD* para el despliegue de retos, el sistema persigue reducir la carga operacional del alojamiento de CTFs a un nivel manejable, permitiendo que instructores y organizaciones estudiantiles puedan ejecutar competiciones con una intervención manual mínima. La plataforma ha sido diseñada con la extensibilidad como premisa, con el objetivo a largo plazo de evolucionar hacia un servicio en producción capaz de dar soporte tanto a eventos internos de la universidad como, potencialmente, a clientes externos.

El resto del artículo se organiza como sigue. La sección II revisa el trabajo relacionado sobre plataformas CTF y sistemas de *cyber range*. La sección III describe el proceso de desarrollo en detalle, incluyendo las decisiones de diseño adoptadas y tecnologías empleadas para abordar dichas decisiones. La sección IV presenta los resultados obtenidos. La sección V esboza el trabajo futuro y la sección VI cierra el artículo con las conclusiones.

II. ESTADO DEL ARTE

II-A. Plataformas CTF e Infraestructura de Competición

El problema del alojamiento de competiciones de ciberseguridad ha sido abordado desde múltiples perspectivas en la literatura científica. Wi *et al.* [1] propusieron *Git-based CTF*, una aproximación ligera para organizar competiciones de ataque y defensa en el aula que minimiza los costes operacionales para el profesorado. Su aportación clave fue identificar que la infraestructura de control de versiones ya existente (repositorios *Git*) podía servir como columna vertebral para la distribución de retos y la recepción de soluciones, eliminando la necesidad de servidores dedicados para la competición. Aunque la propuesta resultó eficaz en el contexto académico del *Korea Advanced Institute of Science & Technology* (KAIST), está inherentemente limitada a escenarios de alcance modesto en los que los entornos de los retos no requieren servicios en contenedores dedicados ni aislamiento por usuario.

Una perspectiva más amplia sobre el estado actual de las herramientas CTF la ofrecen Taylor y Arias [2], quienes evaluaron sistemáticamente el ecosistema de *software* en torno a las competiciones CTF, distinguiendo entre motores de juego y componentes de reto. Su análisis identificó una brecha significativa entre las plataformas de retos estáticos y la infraestructura dinámica capaz de soportar entornos de reto por instancia. Concluyen que la mayoría de los motores de juego de código abierto carecen de soporte para el aprovisionamiento dinámico de instancias de reto aisladas, una limitación que el presente trabajo aborda directamente.

Entre las plataformas de gestión CTF de código abierto, *CTFd* [3] se ha convertido en el estándar *de facto* para la logística competitiva: registro de equipos, gestión del marcador, envío de soluciones y sistema de pistas. Desarrollado originalmente para la competición *Cyber Security Awareness Worldwide* (CSAW) de la Universidad de Nueva York, *CTFd* prioriza la facilidad de despliegue y la extensibilidad mediante una arquitectura de *plugins*. Sin embargo, el alcance de *CTFd* se limita a la capa de gestión de la competición; no aborda el aprovisionamiento ni la gestión del ciclo de vida de la

infraestructura de retos. En consecuencia, las organizaciones que utilizan *CTFd* deben resolver de forma independiente el problema del despliegue y el escalado de los entornos subyacentes.

FBCTF de Facebook [4] representó una alternativa destacable por su interfaz visualmente rica y su marcador estilo *mapa mundi*. *FBCTF* ofrecía una estética superior a *CTFd*, pero resultó significativamente más difícil de instalar y mantener. Tal como señalan evaluaciones comparativas [5], *FBCTF* es más adecuado para competiciones públicas a gran escala donde el impacto visual es prioritario, pero su complejidad operacional lo hace poco apto para entornos académicos con recursos *DevOps* limitados. Además, el proyecto ha sido discontinuado y ya no recibe mantenimiento activo.

Un estudio exhaustivo de Kucek y Leitner [6] examinó ocho plataformas CTF de código abierto y concluyó que, si bien la funcionalidad básica era en general consistente entre ellas, las opciones de configuración del juego varían sustancialmente. El estudio subraya que ninguna plataforma existente ofrecía soporte integrado para entornos de reto dinámicos, aislamiento de contenedores por usuario o escalado automático, confirmando que la capa de infraestructura sigue siendo una laguna persistente en el ecosistema CTF.

II-B. Cyber Ranges

En el extremo más sofisticado del espectro, plataformas de *cyber range* como *KYPO* [7] proporcionan entornos completamente virtualizados capaces de simular topologías de red complejas para actividades de formación. Desarrollado en la Universidad Masaryk desde 2013, *KYPO CRP* está construido sobre *OpenStack* y ofrece capacidades de gestión de *sandboxes*, emulación de red y monitorización integrada. La plataforma ha sido empleada en ejercicios de entrenamiento con cientos de participantes y soporta tanto casos de uso educativos como de investigación.

En el ámbito comercial y semiprofesional, plataformas como *Hack The Box* [8] y *TryHackMe* [9] pueden entenderse igualmente como *cyber ranges* orientados a la formación práctica en ciberseguridad: ofrecen entornos virtualizados accesibles en línea con máquinas y retos que los usuarios atacan de forma controlada. Aunque su foco es la formación individual y su modelo es principalmente de suscripción, ilustran cómo el concepto de *cyber range* puede materializarse a distintas escalas y con distintos propósitos. En el presente trabajo se adopta esta misma comprensión amplia del término, considerando que una plataforma CaaS de alojamiento de CTFs constituye, en esencia, un *cyber range* ligero especializado en el formato de competición.

No obstante, las plataformas de la clase *KYPO* son arquitectónicamente complejas y requieren recursos *hardware* considerables, además de experiencia técnica especializada para su despliegue y operación. Su caso de uso principal son los ejercicios de ciberdefensa a gran escala que simulan entornos de red empresariales, un alcance considerablemente más amplio que el que requiere una competición CTF de tipo *jeopardy*. La sobrecarga asociada al aprovisionamiento de máquinas virtuales completas por cada instancia de reto, frente al uso de contenedores ligeros, hace que estas plataformas sean menos adecuadas para el alojamiento rápido, frecuente y económico de CTFs que persigue el presente trabajo.

II-C. Resumen y Posicionamiento

El panorama existente revela una división clara entre herramientas ligeras de gestión de competiciones, que gestionan la puntuación y la logística de equipos pero ignoran la infraestructura, y plataformas de *cyber range* completas, que ofrecen entornos virtualizados ricos pero conllevan una sobrecarga operacional significativa. Existe un espacio entre estos extremos para una plataforma que combine infraestructura de retos automatizada y reproducible con una usabilidad práctica en entornos académicos con recursos limitados. El presente trabajo ocupa precisamente ese espacio, apuntando a un despliegue *Proxmox* en las propias instalaciones con retos basados en contenedores, despliegue *CI/CD* automatizado y un enfoque centrado en la simplicidad operacional.

III. DESARROLLO

Antes de describir las decisiones de arquitectura y su implementación, conviene establecer **qué es un reto CTF** desde el punto de vista técnico, ya que esta caracterización es la que justifica buena parte de las decisiones de diseño adoptadas.

Un reto CTF es una unidad autocontenida y reproducible compuesta por el código fuente del servicio vulnerable, los recursos necesarios para construirlo y los ficheros de configuración que describen cómo ejecutarlo. En el contexto de esta plataforma, los retos provienen de **fuentes fiables**: son desarrollados y mantenidos por nuestros propios colaboradores y desarrolladores, lo que garantiza su calidad, seguridad y adecuación pedagógica. Para la participación en los eventos, se utilizan **usuarios invitados** cuyo acceso queda acotado al entorno de competición, sin privilegios sobre la infraestructura subyacente. A partir de ese código fuente se genera una imagen *Docker* que encapsula el entorno completo del reto: el sistema operativo base, las dependencias, el servicio en ejecución y la *flag* que el participante debe encontrar. Esta imagen puede instanciarse como un contenedor en cualquier sistema que disponga de *Docker*, produciendo un entorno de ejecución idéntico con independencia del *hardware* o el sistema operativo subyacente. Dado que cada reto es una unidad autosuficiente que no asume nada sobre el entorno en el que se ejecuta, es posible desplegar, replicar, detener y sustituir instancias de reto de forma programática y sin efectos sobre el resto de la infraestructura.

La plataforma está diseñada específicamente para CTF de **formato jeopardy**, que es la modalidad adoptada por la UPNA en sus eventos de ciberseguridad. En este formato, los retos se presentan de manera independiente y clasificados por categoría (ingeniería inversa, explotación web, criptografía, análisis forense, explotación de binarios, etc.) y nivel de dificultad. Cada reto es autónomo y tiene asociada una *flag* única cuya presentación correcta otorga puntos. A diferencia del formato *ataque-defensa*, los participantes no interactúan entre sí a través de la infraestructura, lo que simplifica considerablemente los requisitos de aislamiento y orquestación.

La arquitectura descrita a continuación pretende servirse del formato de los retos anteriores para proporcionar una plataforma de alojamiento de competiciones CTF que sea reproducible, escalable y operacionalmente sencilla, permitiendo a la Universidad Pública de Navarra organizar eventos de ciberseguridad de forma recurrente sin incurrir en una carga

administrativa desproporcionada. Para ello, la arquitectura integra herramientas de Infraestructura como Código que automatizan el aprovisionamiento y la configuración de los entornos de reto, eliminando la dependencia de procedimientos manuales propensos a errores. Mediante la orquestación de contenedores, el balanceo de carga y el mantenimiento en las sesiones establecidas, el sistema garantiza que cada participante disponga de un entorno de reto aislado, persistente y siempre disponible, independientemente de la carga que soporte la plataforma en cada momento. Además, la incorporación de un *pipeline* de integración y despliegue continuo, permite a los autores de retos que publiquen y actualicen sus desafíos de forma continua sin necesidad de intervenir sobre la infraestructura subyacente, desacoplando el desarrollo del despliegue.

III-A. Diseño de la Arquitectura

El punto de partida del diseño fue establecer un conjunto de requisitos funcionales que la plataforma debía satisfacer para resultar útil en un contexto de competición real. El primero y más fundamental es la **disponibilidad continua de los retos**: cada desafío debe permanecer accesible durante toda la duración del evento sin requerir intervención manual, lo que implica que los entornos de reto han de ser resilientes ante fallos individuales de contenedores. Para ello se decidió que cada reto se desplegara con múltiples instancias en ejecución simultánea, de forma que el fallo de una réplica no interrumpiera el servicio para los participantes.

Esta decisión introdujo de inmediato la necesidad de un **balanceador de carga** que distribuyese el tráfico entrante entre las réplicas disponibles de cada reto. Sin un elemento intermediario que gestione el reparto de conexiones, los participantes deberían conocer la dirección de una réplica concreta, lo que anularía el beneficio de la replicación y complicaría la gestión de acceso.

Sin embargo, la replicación de instancias de reto entra en tensión directa con otro requisito clave: la **preservación del progreso del participante**. Muchos retos CTF, especialmente los de categorías como explotación de binarios o intrusión en sistemas, mantienen estado en el lado del servidor: un proceso en ejecución, un fichero modificado, una sesión de *shell* activa. Si el balanceador de carga enruta conexiones sucesivas de un mismo participante a réplicas distintas, el progreso acumulado en la réplica original se pierde. Mantener la afinidad de sesión a nivel de aplicación resultaría intrusivo, ya que requeriría modificar el código de cada reto para sincronizar estado entre réplicas, lo que es inviable dado que los retos son desarrollados de forma independiente por distintos autores.

Otra decisión de diseño central fue **confinar cada reto en su propia red privada**, aislándolo del resto de retos y del tráfico general de la infraestructura. Este aislamiento es un requisito de seguridad básico: impide que un participante que comprometa el entorno de un reto pueda lateralizar hacia otros retos o hacia la infraestructura de gestión. Como consecuencia directa, el tráfico exterior no puede alcanzar los contenedores de reto de forma directa, ya que estos residen en redes internas no enrutables desde Internet, lo que obliga a disponer de un **punto de entrada controlado** que traduzca las conexiones externas hacia las redes privadas internas.

Finalmente, se tomó la decisión de **separar el aprovisionamiento de la infraestructura de la configuración de los servicios** que corren sobre ella. Definir toda la infraestructura de forma declarativa garantiza que los entornos sean reproducibles: un mismo conjunto de ficheros de configuración debe ser capaz de generar una infraestructura idéntica en cualquier momento, eliminando la dependencia de procedimientos manuales documentados informalmente. La figura 1 ilustra la arquitectura resultante de estas decisiones.




Figura 1: Arquitectura de alto nivel de la plataforma CaaS. El tráfico de Internet entra por un *frontend NAT* y se distribuye entre los nodos *backend*. Cada *backend* aloja múltiples clústeres de contenedores (uno por reto), con un balanceador de carga que proporciona distribución de tráfico y persistencia de sesiones.

III-B. Implementación de la Arquitectura

Proxmox como hipervisor base. Toda la infraestructura se despliega sobre *Proxmox VE* [10], un hipervisor de código abierto que permite gestionar tanto máquinas virtuales como Contenedores Linux (LXC) desde una única plataforma. En este proyecto se emplean exclusivamente contenedores LXC como unidad de aislamiento a nivel de *host*, ya que ofrecen un arranque más rápido y un menor consumo de recursos que las máquinas virtuales completas, manteniendo un nivel de aislamiento suficiente para los distintos roles de la infraestructura (*frontend NAT* y nodos *backend*).

Terraform para el aprovisionamiento declarativo. La creación de los contenedores LXC en *Proxmox* se gestiona mediante *Terraform* [11] a través del proveedor *Telmate* que mantiene la comunidad. Se definió una estructura modular con módulos independientes para los nodos *backend* (`backend_lxc`), el nodo *frontend NAT* (`frontend_lxc`) y la gestión de grupos de recursos (`pool`). El estado de *Terraform* se almacena en un sistema de control de versiones, lo que garantiza que la infraestructura sea completamente reproducible a partir de la especificación declarativa y que cualquier cambio quede registrado. *Terraform* cubre así el requisito de separación entre aprovisionamiento e infraestructura, pero deliberadamente no gestiona la configuración del *software* que corre dentro de los contenedores, responsabilidad que recae en *Ansible*.

Ansible para la configuración de los nodos. Una vez aprovisionados los contenedores LXC, *Ansible* [12] se encarga

de su configuración mediante roles y *playbooks*. Para los nodos *backend* se definen tareas de instalación de *Docker*, creación de usuarios de servicio y configuración de la red *overlay*. Para el nodo *frontend NAT* se gestionan las reglas de enrutamiento. Esta separación de responsabilidades entre *Terraform* y *Ansible* mantiene cada herramienta dentro de su dominio natural y evita los patrones frágiles que surgen cuando *Terraform* intenta asumir tareas de configuración mediante aprovisionadores de *shell*.

Iptables para el enrutamiento externo. El nodo *frontend NAT* se configura con reglas DNAT de *iptables* que traducen las conexiones entrantes desde la red pública hacia los *backends* correspondientes. Un *playbook* de *Ansible* (`iptables-conf.yml`) genera y aplica estas reglas automáticamente a partir del inventario de infraestructura, y las persiste para que sobrevivan a reinicios del sistema. Este mecanismo resuelve el problema del punto de entrada controlado identificado en el diseño: el tráfico exterior llega al *frontend*, que lo reenvía al *backend* adecuado sin que los contenedores de reto necesiten exponerse directamente a Internet.

Docker Swarm para la orquestación de contenedores. Dentro de cada nodo *backend*, los retos se despliegan como servicios de *Docker Swarm* [13] en lugar de como contenedores individuales. Cada servicio gestiona un conjunto de réplicas de un mismo reto, lo que aborda directamente el requisito de disponibilidad continua: si una réplica falla, *Swarm* la reemplaza automáticamente. Los servicios se configuran con modo de *endpoint DNS Round Robin* (DNSRR), de forma que el DNS interno de *Swarm* resuelve el nombre del servicio devolviendo cíclicamente las direcciones IP de sus réplicas activas. Cada reto reside en su propia red *overlay* gestionada por *Swarm*, lo que proporciona el aislamiento entre retos requerido por el diseño.

HAProxy para el balanceo de carga y la persistencia de sesiones. *HAProxy* [14] se despliega como contenedor en cada *backend*, actuando como proxy inverso entre el *frontend NAT* y los servicios *Swarm*. Para cada reto, *HAProxy* consulta al DNS de *Swarm* para obtener las direcciones de todas las réplicas activas y distribuye las conexiones entrantes entre ellas mediante *Round Robin*. La persistencia de sesiones, identificada en el diseño como requisito irreconciliable con la replicación a nivel de aplicación, se resuelve aquí mediante las *stick-tables* de *HAProxy*: una tabla en memoria que asocia cada dirección IP de origen con la réplica asignada en su primera conexión. Mientras esa réplica permanezca activa, todas las conexiones posteriores desde la misma IP se dirigen a ella, preservando el estado del servidor sin ninguna modificación en el código del reto. La configuración de *HAProxy* se genera automáticamente mediante una plantilla *Ansible* (`haproxy.tpl`) que se rellena con los metadatos de los retos desplegados en cada momento.

Pipeline CI/CD y modalidades de trabajo. Para automatizar el ciclo de vida de los retos se implementó una *pipeline CI/CD* basada en *Git*, ilustrada en la figura 2.

Un *hook post-receive* en el repositorio construye un artefacto comprimido con cada *push* que realiza el desarrollador y lo almacena en la rama *artifacts*. Un script `pipeline.sh`, ejecutado periódicamente como tarea cron en cada *backend*, comprueba si existen nuevos




Figura 2: Flujo del pipeline CI/CD.

artefactos, los compara con las versiones desplegadas y actualiza los servicios *Swarm* correspondientes, informando del resultado al repositorio mediante un fichero de estado (`latest-build.txt`). Esta *pipeline* soporta dos modalidades de trabajo: una **modalidad centrada en el desarrollo** (*rolling updates*), en la que los autores de retos publican cambios que se propagan automáticamente a los *backends*, y una **modalidad centrada en el despliegue**, en la que un administrador aprovisiona desde cero una infraestructura *ad-hoc* seleccionando un catálogo de retos concreto.

IV. RESULTADOS

La plataforma desarrollada logra satisfactoriamente una serie de objetivos funcionales que responden a los desafíos operacionales identificados durante las fases anteriores de desarrollo.

Aprovisionamiento de infraestructura reproducible: La combinación de *Terraform* y *Ansible* permite crear un entorno *backend* completo desde cero de forma repetible. Partiendo de un host *Proxmox* recién configurado, toda la infraestructura, incluyendo el *frontend NAT*, los nodos *LXC backend*, la inicialización del clúster *Docker Swarm* y el despliegue de *HAProxy*, puede levantarse ejecutando un número reducido de *scripts* definidos.

Despliegue automatizado de retos: La *pipeline CI/CD* basada en *hooks* de *Git* y el *script pipeline.sh* permite a los autores de retos publicar actualizaciones en el repositorio y que éstas se reflejen automáticamente en el despliegue activo sin intervención administrativa manual. El enfoque basado en artefactos desacopla el proceso de construcción del proceso de despliegue, reduciendo el riesgo de despliegues parciales o fallidos.

Persistencia de sesiones de usuario: El mecanismo de *stick-table* de *HAProxy* garantiza que un participante que se conecta a un reto sea dirigido consistentemente a la misma réplica del contenedor durante toda su sesión. Esto es esencial para los tipos de retos que mantienen estado del lado del servidor. La afinidad de sesión se mantiene de forma transparente sin ninguna modificación en el código del reto.

Replicabilidad de retos y alta disponibilidad básica: Los servicios *Docker Swarm* permiten escalar cada reto a múltiples réplicas, proporcionando distribución básica de carga y resiliencia ante fallos de contenedores individuales. Aunque el escalado requiere actualmente intervención manual del administrador (mediante `docker service scale`), el mecanismo subyacente está en su lugar.

Conectividad externa: La cadena de enrutamiento basada en *iptables* y el proxy inverso *HAProxy* proporciona un

camino de conectividad externa limpio desde Internet público a través del *frontend NAT* hasta los contenedores de retos correspondientes, sin necesidad de que los retos expongan puertos directamente en el *host*.

Especificación clara del formato de reto: La plataforma define un contrato mínimo para el empaquetado de retos: una imagen *Docker* construida en el registro de contenedores, un `docker-compose.yml` que especifica la pertenencia a la red *overlay* y el modo de *endpoint DNSRR*, y un par de *scripts* de preparación e inicio adaptados para el despliegue con *Swarm*. Este contrato es suficientemente reducido como para adoptarse sin una refactorización significativa de los retos existentes.

V. TRABAJO FUTURO

Si bien la plataforma logra sus principales objetivos funcionales, se han identificado varias áreas de mejora para fases posteriores de desarrollo.

Monitorización y observabilidad: La integración de *Prometheus*, iniciada y posteriormente pausada en las primeras fases de desarrollo, sigue siendo una prioridad. Las métricas de interés incluyen la disponibilidad de los contenedores, el número de conexiones por reto y la utilización de recursos por nodo backend. Más allá de las métricas de infraestructura, el desarrollo de sondas *Prometheus* capaces de validar el correcto funcionamiento de los retos desplegados (por ejemplo, verificando que el servicio acepta conexiones y devuelve la respuesta inicial esperada) mejoraría significativamente la visibilidad operacional.

Escalado automático: El mecanismo de escalado actual requiere la intervención manual del administrador para ajustar el número de réplicas. Un mecanismo de autoescalado basado en la demanda, potencialmente activado por los recuentos de conexiones informados por *HAProxy* o por las métricas de utilización de recursos de *Prometheus*, reduciría la carga operacional y mejoraría la experiencia de los participantes en periodos de carga elevada. La integración con la API de *Proxmox* para aprovisionar dinámicamente nodos *LXC backend* adicionales cuando los *backends* existentes se aproximen a su capacidad permitiría un escalado elástico a nivel de infraestructura.

Interfaz de administración: Se ha desarrollado parcialmente una interfaz web de administración, aunque aún no se encuentra en una versión definitiva. Esta interfaz permitiría a instructores sin perfil técnico gestionar el despliegue de retos, monitorizar la actividad de los participantes y configurar los parámetros de la competición sin acceso directo a la línea de comandos. También se estudia la integración con plataformas de gestión CTF estándar como *CTFd*, para proporcionar a los participantes un marcador y un sistema de envío de soluciones familiares.

Estandarización del flujo y plantillas de retos: La especificación actual del formato de reto, si bien funcional, podría beneficiarse de una estandarización más rigurosa. Un repositorio de plantillas de retos con *scripts* de despliegue, una única configuración para la integración continua de retos y documentación sobre como se deben diseñar, rebajaría la barrera de entrada para los autores de retos y garantizaría la coherencia en todo el catálogo.

Alta disponibilidad de HAProxy: La arquitectura actual despliega una única instancia de HAProxy por *backend*, creando un potencial punto único de fallo. Un despliegue multi-instancia de HAProxy con estado compartido (mediante la configuración de *peers* de HAProxy) y una IP virtual flotante eliminaría esta vulnerabilidad.

Mejora del seguimiento del estado de despliegue: El mecanismo actual de notificación de estado almacena un único estado de despliegue por reto sin indicar qué instancia *backend* lo aloja. Ampliar el fichero de estado `latest-build.txt` para incluir el estado por *backend* permitiría una monitorización más granular y daría soporte a despliegues *multi-backend* en los que diferentes retos se sirven desde diferentes *backends*.

Integración con modelos de IA: se plantea la integración de retos que incorporen modelos de Inteligencia Artificial, tanto clásicos como generativos, dentro del ecosistema de la plataforma. En particular, se propone el desarrollo de mecanismos de orquestación que permitan desplegar servicios basados en modelos de lenguaje (LLM) como parte de los propios desafíos o como herramientas auxiliares. Estos sistemas podrían actuar como asistentes conversacionales capaces de proporcionar pistas dinámicas, retroalimentación contextualizada o tutorización progresiva en función del estado del reto y del comportamiento del usuario. Asimismo, se estudiará la viabilidad de integrar estos servicios dentro del *pipeline CI/CD* existente, permitiendo la actualización automática de modelos o prompts asociados a cada desafío.

VI. CONCLUSIONES

En este artículo se ha presentado el diseño y el desarrollo iterativo de una plataforma CTF como Servicio construida sobre la virtualización *Proxmox* mediante *Terraform*, *Ansible*, *Docker Swarm* y *HAProxy*. La plataforma aborda las principales barreras operacionales para el alojamiento de competiciones CTF en entornos académicos: la complejidad del aprovisionamiento de infraestructura, la ausencia de *pipelines* de despliegue automatizadas y la dificultad de mantener la persistencia de sesiones entre contenedores replicados.

A lo largo de una serie de iteraciones de desarrollo, el sistema evolucionó desde un *script* de despliegue manual hasta una pila de infraestructura cohesionada y reproducible con dos modalidades operacionales diferenciadas que dan soporte tanto a los equipos de desarrollo como a los administradores de despliegue. La plataforma resultante ha demostrado la viabilidad del alojamiento CTF automatizado y basado en Infraestructura como Código sobre *hardware* propio, con una trayectoria clara hacia la oferta CTF como Servicio de carácter comercial que la UPNA tiene como horizonte.

La plataforma constituye una base sobre la que construir capacidades más avanzadas, incluyendo el escalado automático, la monitorización integrada y una interfaz de administración pulida, en futuros ciclos de desarrollo. El trabajo demuestra que las herramientas de código abierto, cuando se combinan de forma razonada, pueden reducir drásticamente la carga operacional del alojamiento CTF de nivel profesional.

AGRADECIMIENTOS

Este trabajo ha contado con el apoyo de la Cátedra de Ciberseguridad creada por la Universidad Pública de Navarra (UPNA) y su compromiso con el avance de la formación y el fomento de la innovación en ciberseguridad.

REFERENCIAS

- [1] S. Wi, J. Choi, and S. K. Cha, "Git-based ctf: A simple and effective approach to organizing in-course attack-and-defense security competition," in *2018 USENIX Workshop on Advances in Security Education (ASE 18)*. Baltimore, MD, USA: USENIX Association, Aug. 2018. [Online]. Available: <https://www.usenix.org/conference/ase18/presentation/wi>
- [2] G. M. Taylor and A. Arias, "Ctf: State-of-the-art and building the next generation," Semantic Scholar, 2024. [Online]. Available: <https://api.semanticscholar.org/CorpusID:267660094>
- [3] CTFd Development Team, "Ctf: The easiest capture the flag platform," 2024. [Online]. Available: <https://ctfd.io/>
- [4] Facebook, "Fbctf: Facebook capture the flag," GitHub repository. [Online]. Available: <https://github.com/facebook/fbctf>
- [5] S. Karagiannis, E. Maragkos-Belmpas, and E. Magkos, "An analysis and evaluation of open source capture the flag platforms as cybersecurity e-learning tools," in *Information Security Education. Information Security in Action*. Cham: Springer International Publishing, 2020, pp. 61–77.
- [6] S. Kucek and M. Leitner, "An empirical survey of functions and configurations of open-source capture the flag (ctf) environments," *Journal of Network and Computer Applications*, vol. 157, p. 102419, 2020.
- [7] J. Vykopal, R. Ošlejšek, P. Čeleda, M. Vižváry, and D. Továrnák, "Kypo cyber range: Design and use cases," in *Proceedings of the 12th International Conference on Software Technologies (ICSOT 2017)*, 2017, pp. 310–321.
- [8] Hack The Box Ltd., "Hack The Box — hacking training for the best," <https://www.hackthebox.com>, 2025, consultado en 2025.
- [9] TryHackMe Ltd., "TryHackMe — learn cyber security," <https://tryhackme.com>, 2025, consultado en 2025.
- [10] Proxmox Server Solutions GmbH, "Proxmox virtual environment." [Online]. Available: <https://www.proxmox.com/>
- [11] HashiCorp, "Terraform: Infrastructure as code." [Online]. Available: <https://www.terraform.io/>
- [12] Red Hat, "Ansible: Automation for everyone." [Online]. Available: <https://www.ansible.com/>
- [13] Docker Inc., "Docker swarm mode overview." [Online]. Available: <https://docs.docker.com/engine/swarm/>
- [14] HAProxy Technologies, "Haproxy: The reliable, high performance tcp/http load balancer." [Online]. Available: <https://www.haproxy.org/>

Marco para el diseño y certificación de formación en ciberseguridad alineada con el ECSF mediante Cyber Ranges y entornos virtuales de aprendizaje

Julia Sánchez
j.sanchez@salle.url.edu

José-María Romero
jm.romero@salle.url.edu

Alan Briones
alan.briones@salle.url.edu

Guiomar Corral
guiomar.corral@salle.url.edu

Universitat Ramon Llull – La Salle
Sant Joan de la Salle, 42, 08022, Barcelona

Resumen- El *European Cybersecurity Skills Framework* (ECSF) define perfiles ocupacionales, tareas y competencias asociadas, pero no establece niveles competenciales explícitos ni un procedimiento metodológico que permita su implementación sistemática en programas formativos y esquemas de certificación. Este trabajo presenta el *REWIRE Courses and Certification Framework* (REWIRE C²F), un modelo para la operacionalización del ECSF basado en una cadena de trazabilidad que conecta perfil profesional, competencias, resultados de aprendizaje, actividades prácticas y certificación. El marco integra el modelo instruccional ADDIE, la definición de niveles de competencia alineados con e-CF y EQF, la evaluación competencial en entornos simulados mediante Cyber Ranges y un esquema certificador conforme a ISO/IEC 17024. La metodología ha sido aplicada en el proyecto europeo REWIRE y posteriormente en NG-SOC, demostrando su transferibilidad. La principal contribución radica en la definición de un procedimiento replicable que articula diseño curricular, evaluación competencial y certificación alineada con estándares europeos.

Index Terms- Alineación con el ECSF, Cyber Ranges, ADDIE, ISO/IEC 17024, Certificación basada en competencias

I. INTRODUCCIÓN

El *European Cybersecurity Skills Framework* (ECSF) [1], desarrollado por ENISA, define doce perfiles ocupacionales con tareas, conocimientos y habilidades asociadas. Sin embargo, constituye una taxonomía de referencia que no establece niveles de *expertise* explícitos, ni proporciona un procedimiento metodológico para traducir los perfiles ocupacionales en resultados de aprendizaje, estructuras curriculares y mecanismos de evaluación certificable.

Esta ausencia de operacionalización genera una brecha entre el ECSF y su implementación formativa. Con frecuencia, los programas declaran alineación con el ECSF sin mecanismos formales de trazabilidad entre perfil profesional, competencias requeridas, diseño formativo y evaluación, lo que dificulta la comparabilidad y la correspondencia con los perfiles europeos.

El *REWIRE Courses and Certification Framework* (REWIRE C²F) [2] propone un modelo metodológico para resolver esta brecha. El marco articula una cadena estructurada de correspondencia:

Perfil ECSF → Tareas → Conocimientos y habilidades → Resultados de aprendizaje → Módulos formativos → Actividades prácticas → Evaluación → Esquema de certificación

Desde el punto de vista metodológico, REWIRE C²F combina: (i) el modelo instruccional ADDIE como estructura de diseño sistemático, (ii) la integración de ejercicios en Cyber Range como mecanismo de evaluación práctica en entornos simulados controlados, y (iii) un esquema de certificación alineado con los principios de la norma ISO/IEC 17024 [3], orientado a la verificación de competencias y no únicamente de participación.

De este modo, REWIRE C²F formaliza un procedimiento replicable para su implementación coherente en programas formativos y esquemas de certificación alineados con estándares europeos.

II. REWIRE C²F: ARQUITECTURA METODOLÓGICA Y OPERACIONALIZACIÓN DEL ECSF

El REWIRE C²F es un modelo metodológico para la implementación sistemática del ECSF en programas formativos y esquemas de certificación. Su arquitectura (Fig. 1) articula una cadena de trazabilidad que conecta perfil profesional, diseño curricular, evaluación y certificación.

El proceso comienza con el análisis de necesidades y la selección del perfil ECSF, incluyendo la revisión del perfil, la identificación de tareas asociadas y el mapeo explícito perfil–tareas–competencias. A partir de este mapeo se definen niveles competenciales alineados con e-CF [4] y su correspondencia con EQF [5], lo que permite delimitar requisitos previos, elementos evaluables y alcance formativo.

La fase de diseño vincula las competencias y niveles definidos con resultados de aprendizaje trazables presentados en una estructura modular coherente. La modularidad permite agrupar competencias en unidades formativas independientes pero alineadas, facilitando su reutilización y adaptación a distintos contextos. La fase de desarrollo concreta esta




Fig. 1. REWIRE C²F, metodología para crear cursos profesionales de ciberseguridad

estructura en contenidos teóricos y escenarios prácticos desplegados en entornos de Cyber Range.

La implementación se realiza mediante entornos virtuales de aprendizaje, integrando la gestión de actividades prácticas.

Finalmente, la fase de evaluación recoge *feedback* sobre la implementación del curso para ajustar niveles competenciales y mejorar actividades formativas y de evaluación.

El esquema de certificación, alineado con ISO/IEC 17024, se integra como componente estructural del marco y se fundamenta en la correspondencia explícita entre perfil ECSF, niveles competenciales, resultados de aprendizaje y mecanismos de evaluación.

De este modo, REWIRE C²F no se limita a establecer una alineación nominal con el ECSF, sino que formaliza un procedimiento replicable de transformación del marco de referencia en diseño curricular, evaluación estructurada y certificación coherente. La descripción detallada del modelo completo se encuentra en el artículo publicado en IJIS [2]; en este trabajo se presenta una síntesis de sus componentes esenciales con el objetivo de facilitar su comprensión y potencial adopción en entornos académicos y profesionales.

III. VALIDACIÓN Y TRANSFERIBILIDAD DEL MARCO METODOLÓGICO

La arquitectura metodológica fue implementada inicialmente en el proyecto europeo REWIRE [6], donde se diseñaron e impartieron programas alineados con cuatro perfiles ECSF: *Chief Information Security Officer (CISO)*, *Cyber Incident Responder*, *Cyber Threat Intelligence Specialist* y *Penetration Tester*. El marco permitió establecer la trazabilidad entre perfil profesional, niveles competenciales, resultados de aprendizaje, módulos formativos y mecanismos de evaluación, integrando el entorno virtual de aprendizaje (LearnDash) y los escenarios de Cyber Range para facilitar la gestión de contenidos teóricos y actividades prácticas.

El despliegue se realizó en ciclos iterativos, ajustando niveles, requisitos previos y mecanismos de evaluación a partir de la experiencia acumulada. La evolución técnica del entorno virtual de aprendizaje y su integración con el Cyber Range mejoraron progresivamente la coherencia del proceso formativo y evaluador.

La transferibilidad del marco se validó posteriormente en el proyecto NG-SOC [7], aplicando la metodología a nuevos perfiles y en una plataforma virtual distinta (OpenEdX). El proceso incluyó identificación de carencias competenciales y estructuración modular manteniendo alineación con el ECSF y los niveles e-CF/EQF, lo que confirma la adaptabilidad a distintos contextos tecnológicos y organizativos.

IV. LIMITACIONES Y ALCANCE

Aunque el REWIRE C²F establece un procedimiento estructurado para la operacionalización del ECSF, presenta limitaciones. En primer lugar, depende de la evolución del ECSF. Actualizaciones en los perfiles, tareas o competencias pueden requerir la revisión de mapeos y niveles establecidos.

En segundo lugar, la asignación y propagación de niveles alineados con e-CF y EQF implica decisiones metodológicas basadas en consenso experto, especialmente en la delimitación de requisitos previos y elementos evaluables para mantener la coherencia del esquema formativo y certificador.

Asimismo, la integración de entornos de Cyber Range

introduce condicionantes técnicos y organizativos, como interoperabilidad entre plataformas, gestión de recursos y disponibilidad de infraestructuras.

Finalmente, el modelo ya ha sido aplicado en distintos proyectos y se prevén evaluaciones complementarias para profundizar en su impacto sobre empleabilidad, progresión profesional y reconocimiento interinstitucional.

Estas limitaciones permiten, por un lado, delimitar con mayor precisión el alcance del modelo y, por otro, establecer una base sólida para futuras líneas de mejora y consolidación.

V. CONCLUSIONES

El *REWIRE Courses and Certification Framework* (REWIRE C²F) formaliza un modelo para la implementación sistemática del ECSF en programas formativos y esquemas de certificación, estableciendo una cadena de trazabilidad entre perfil profesional, niveles competenciales, resultados de aprendizaje, estructura modular, evaluación y certificación. Su aplicación en los proyectos REWIRE y NG-SOC demuestra la viabilidad y adaptabilidad del enfoque en distintos contextos tecnológicos. El marco integra diseño curricular, evaluación en entornos simulados mediante Cyber Ranges y certificación alineada con estándares europeos, contribuyendo a una mayor coherencia en la formación en ciberseguridad. Asimismo, proporciona una base metodológica para el desarrollo de esquemas formativos comparables y transferibles en el ámbito europeo abriendo líneas de investigación en interoperabilidad, coherencia estructural entre perfiles y niveles y análisis de impacto en la progresión profesional.

AGRADECIMIENTOS

Este trabajo ha sido desarrollado en el marco de los proyectos europeos REWIRE (Erasmus+ Programme, Grant Agreement No. 621701-EPP-1-2020-1-LT-EPPKA2-SSA-B) y NG-SOC (European Cybersecurity Competence Centre, Grant Agreement No. 101145874), financiados por la Unión Europea. Los autores agradecen la contribución de los socios de NG-SOC en la validación del marco presentado.

REFERENCIAS

- [1] ENISA. *European cybersecurity skills framework (ECSF)*. <https://www.enisa.europa.eu/sites/default/files/publications/European%20Cybersecurity%20Skills%20Framework%20Role%20Profiles.pdf>, 2022. Último acceso: 2025-04-25.
- [2] Sánchez, J., Briones, A., Ricci, S., Čegan, J., Chatzopoulou, A., Danidou, Y., Menegatos, A., Corral, G. (2026). A framework for designing and certifying ECSF-aligned cybersecurity training through cyber ranges and virtual learning environments: J. Sánchez, et al. *International Journal of Information Security*, 25(2), 46.
- [3] ISO Committee on conformity assessment (CASCO). *Iso/iec 17024:2012. conformity assessment — general requirements for bodies operating certification of persons*. <https://www.iso.org/obp/ui/en/#iso:std:iso-iec:17024:ed-2:v1:en>, 2012. Último acceso: 2025-04-25.
- [4] European Committee for Standardization (CEN). *e-competence framework (e-cf) - a common european framework for ict professionals in all sectors - part 1: Framework*. https://standards.cencenelec.eu/dyn/www/f?p=205:110:0:::FSP_PROJECT:67073&cs=15E62ED24D608A5F10D6BEE8E6D50FA10, 2019. Último acceso: 2025-09-25.
- [5] European Commission. *The european qualifications framework for lifelong learning (eqf)*. [https://eur-lex.europa.eu/legal-content/EN/TXT/HTML/?uri=CELEX:32017H0615\(01\)&from=EN](https://eur-lex.europa.eu/legal-content/EN/TXT/HTML/?uri=CELEX:32017H0615(01)&from=EN), 2017. Último acceso: 2025-05-08.
- [6] REWIRE Project. <https://rewireproject.eu/>. Último acceso: 2025-09-27.
- [7] NG-SOC Project. <https://ng-soc.eu/>. Último acceso: 2025-09-27.

MARCIM-WG: A cyber wargame proposal based on math modeling applied in a naval scenario

Diego Cabuya-Padilla¹, Daniel Díaz-López^{2,3}, Carlos Castaneda-Marroquín⁴

¹ ‘Poseidón’ research group, Naval Academy of Strategic Studies, Bogotá, Colombia
diego.cabuya@enap.edu.co

²Department of Information and Communications Engineering, University of Murcia, 30100, Murcia, Spain
danielorlando.diaz@um.es

³School of Engineering, Science and Technology, Universidad del Rosario, Bogotá, Colombia
danielo.diaz@urosario.edu.co

⁴ ‘GICCDN’ research group, ‘Almirante Padilla’ Naval Cadet Academy, Cartagena, Colombia
carlos.castaneda@enap.edu.co

Abstract—As maritime operations increasingly depend on interconnected digital ecosystems, cyber incidents can propagate across maritime networks and degrade critical services. Strengthening strategic Cyber Situational Awareness (CSA) therefore requires training mechanisms that expose decision-makers to evolving attack dynamics, constrained resources, and the need to align actions with incident-response procedures. This paper introduces MARCIM-WG, a learning-oriented maritime cyberdefense wargame designed following the NATO wargaming methodology and implemented as a hybrid tabletop experience combining a physical board (tokens, indicators, and special cards) with analytically-assisted adjudication supported by a computational simulation model. The proposal is specified through High-Level Design (HLD) and Low-Level Design (LLD) specifications and instantiated in a fictional maritime cyber crisis scenario to enable structured decision cycles, friction, and measurable consequences. Validation combines (i) an operational scenario-based assessment under three configurations (pessimistic, neutral/most likely, optimistic) to verify decision sensitivity and outcome coherence, and (ii) a CSA competency and learning-outcome evaluation using a comparative design against an equivalent control group. Results show a +34.0 percentage-point improvement in the intervention group, with the largest gains in comprehension-related competencies.

Index Terms—Cyber Situational Awareness (CSA), Cyberdefense, Cybersecurity, Education in cybersecurity, Maritime, Serious Games, Tabletop Exercises (TTX), Wargaming

Contribution type: *Training and educational innovation*

I. INTRODUCTION

The maritime sector concentrates assets and services that sustain global trade and national security, while increasingly relying on interconnected digital ecosystems. This dependency expands the attack surface and increases the likelihood that cyber incidents translate into operational disruption, economic impact, and safety risks across ships, ports, and supporting logistics chains [1], [2], [3], [4]. From a strategic cyberdefense viewpoint, the challenge is not limited to technical containment: leaders must preserve mission continuity under uncertainty, align stakeholders, and anticipate cascading effects across interdependent maritime services [5], [4].

Cyber Situational Awareness (CSA) is pivotal in that context because it supports (i) the perception of relevant cues, (ii) the

comprehension of their meaning in context, and (iii) the projection of plausible future states to guide decisions in dynamic environments [6], [7]. In cyber crises, CSA is operationalized through the ability to translate technical signals into decision-relevant understanding and to prioritize actions under time pressure [8]. In naval systems, achieving actionable awareness requires domain-grounded interpretation of evolving cyber conditions to support timely decisions [9].

Wargames are a practical mechanism to strengthen decision-making in complex, adversarial environments by combining narrative, friction, and iterative learning. In cyberdefense, wargaming enables participants to rehearse decisions, explore trade-offs, and internalize procedures while preserving the essential dynamics of an adaptive adversary [10], [11], [12]. However, cyber wargames are often constrained by limited validation and uneven contextualization [13]. In particular, the specialized use of wargaming to foster CSA within maritime cyberdefense remains scarcely documented, despite the recognized relevance of maritime cyber risk and the growth of maritime cybersecurity research [14], [15], [16].

To address this gap, this paper presents MARCIM-WG, a maritime cyberdefense wargame designed to foster strategic CSA by enabling participants to appropriate crisis-response procedures and protocols through a hybrid experience that combines a physical board with computational adjudication. The objective of MARCIM-WG is to develop CSA competencies—perception, comprehension, and projection—[6], [7] by exposing decision-makers to evolving attack dynamics, resource constraints, and decision–consequence cycles within a fictional cyber crisis. The wargame is conceived and specified following the NATO wargaming methodology [17], progressing from purpose and learning objectives to high-level and low-level specifications, scenario, execution, and results-oriented post-analysis. MARCIM-WG builds on a modeling-and-simulation foundation for maritime cyberdefense and leverages an underlying propagation model to represent crisis evolution and the effects of defensive decisions [18], [16]. Building upon these previous developments, this work extends the SERDUX-MARCIM framework by translating its

mathematical and simulation capabilities into an operational wargaming environment. In this sense, MARCIM-WG represents a methodological and practical evolution, enabling the application of the model in structured decision-making scenarios aimed at developing Cyber Situational Awareness at the strategic level.

The main contributions of this work are as follows:

- A domain-grounded maritime cyberdefense wargame (MARCIM-WG) that explicitly operationalizes Cyber Situational Awareness (CSA) through structured decision cycles, incorporating perception, comprehension, and projection as measurable competencies within a controlled experimental environment.
- The integration of a hybrid tabletop wargaming environment with an analytically-assisted adjudication mechanism, where player decisions are systematically translated into quantitative system-level effects through a computational simulation model, ensuring traceability between actions and outcomes.
- A complete and methodologically consistent specification of the wargame through High-Level Design (HLD) and Low-Level Design (LLD), aligned with NATO wargaming principles, enabling reproducibility and structured implementation in similar contexts.
- The incorporation of a mathematical modeling and simulation core (based on the SERDUX-MARCIM model) into the adjudication process, allowing the representation of cyberattack propagation dynamics and the evaluation of defensive decisions in terms of network states and service availability.
- A competency-oriented validation approach that goes beyond traditional subjective assessments, including a structured instrument to evaluate CSA-related learning outcomes and a comparative analysis against a control group to quantify the educational impact of the wargame.

The novelty of MARCIM-WG lies in the explicit integration of three dimensions that are rarely combined in existing cyber wargaming approaches: (i) the operationalization of Cyber Situational Awareness (CSA) as a central learning objective, rather than as an implicit outcome; (ii) the use of an analytically-assisted adjudication mechanism grounded in a mathematical simulation model, which ensures consistency and traceability between player decisions and system-level effects; and (iii) the articulation of a hybrid environment that combines physical interaction (tabletop elements) with computational modeling to support decision-making under realistic constraints. Unlike many existing cyber wargames and simulation-based training environments that rely primarily on expert judgement or predefined scripts, MARCIM-WG provides a dynamic, model-driven representation of cyberattack propagation and response, enabling participants to explore cause-effect relationships in a structured and measurable manner.

II. STATE OF THE ART

Cyber wargaming is commonly positioned as a bridge between strategic intent and operational decision-making in cyber contexts, enabling structured exploration of adversarial dynamics, constraints, and trade-offs. In this line, MITRE frames cyber wargaming as a mechanism to embed realistic organizational context into decision processes so that leaders can reason about impacts, priorities, coordination, and risk acceptance rather than focusing solely on technical artifacts [10]. Doctrine-oriented contributions likewise emphasize that cyber wargames should translate strategic guidance into actionable courses of action, supported by purposeful adjudication, well-designed injects, and explicit learning objectives to produce defensible and reusable insights [11]. From a methodological standpoint, foundational wargaming perspectives stress disciplined game design and execution to ensure internal coherence between decisions, friction, and consequences, which is especially relevant in cyber environments where uncertainty and adaptation dominate [12].

In parallel, simulation-based training environments and serious games have been widely adopted in cybersecurity and cyberdefense education. These approaches include technical exercises such as capture-the-flag scenarios, red-team/blue-team simulations, and tabletop exercises (TTX), which enable participants to rehearse operational responses under controlled conditions. While these environments are effective for developing technical skills and coordination, they often focus on isolated aspects of cyber incidents and provide limited representation of system-level dynamics and strategic decision-making processes. Additionally, many of these approaches rely on predefined scenarios or expert-driven adjudication, which may reduce traceability between decisions and outcomes and limit reproducibility across different training sessions.

Despite these advantages, reported implementations repeatedly highlight limitations that constrain transferability and educational value: uneven methodological rigor, weak or inconsistent validation, and difficulties in aligning mechanics with measurable competence outcomes [13]. Educational wargaming research and broader game-based learning literature reinforce that effectiveness depends on clear mapping between game activities and intended learning constructs, as well as the availability of instruments that can assess changes in participant competencies beyond subjective impressions [19]. These limitations motivate domain-grounded wargame designs that explicitly operationalize competence development and incorporate traceable adjudication and assessment mechanisms, particularly for specialized contexts where strategic cyber decision-making must be trained and evaluated against explicit targets.

Within this context, Cyber Situational Awareness (CSA) has been identified as a critical capability for effective decision-making in cyber environments. Based on the three-level model of perception, comprehension, and projection, CSA enables decision-makers to interpret technical signals, understand their implications in context, and anticipate possible future states of

a cyber incident. Although CSA has been extensively studied in areas such as cyber monitoring, threat intelligence, and operational security, its explicit integration into cyber wargaming environments remains limited. In many existing wargames, situational awareness is treated as an implicit outcome of participation rather than as a structured objective supported by specific mechanics, decision cycles, and evaluation instruments.

Furthermore, in domain-specific contexts such as maritime cybersecurity, research has primarily focused on risk assessment, protection of critical infrastructures, and regulatory frameworks, with limited attention to training mechanisms that allow strategic-level actors to rehearse decision-making under evolving cyber crisis conditions. The complexity of maritime ecosystems, characterized by interconnected services, multiple stakeholders, and strong dependencies between cyber and physical systems, reinforces the need for approaches that integrate system dynamics with strategic decision processes.

Compared to existing cyber wargames and simulation-based training environments, several gaps can be identified. First, there is often a lack of formal integration between player decision-making and underlying system behavior, resulting in weak traceability between actions and outcomes. Second, the development of Cyber Situational Awareness is rarely addressed as a measurable and explicit objective. Third, validation approaches are frequently limited to qualitative observations, without structured instruments to assess competency development.

In this context, MARCIM-WG addresses these limitations by proposing a domain-grounded maritime cyberdefense wargame that integrates a hybrid tabletop environment with an analytically-assisted adjudication mechanism supported by a computational simulation model. Unlike traditional approaches, the proposal explicitly operationalizes CSA as a core learning objective, structures decision–consequence relationships through model-driven adjudication, and incorporates a competency-based validation strategy. This combination enables a more rigorous, traceable, and educationally grounded approach to cyber wargaming at the strategic level.

III. BACKGROUND

The *NATO Wargaming Handbook* frames wargaming as a purpose-driven activity in which the game design, execution, and analysis are derived from a clearly stated intent (e.g., learning or analysis). From this perspective, a defensible wargame starts by articulating the problem to be explored, the objectives to be achieved, and the roles and responsibilities of the wargaming team and participants, ensuring that the overall setup (scenario, players, rules, and data capture) is coherent with the intended outcomes [17]. The methodology also emphasizes an end-to-end cycle that moves from design and development to execution and exploitation (after-action analysis and reporting), enabling refinement and institutional learning across iterations [17].

A central contribution of the NATO approach is the operationalization of wargame design through four essential

elements—*decisions, friction, consequences, and narrative*. Together, these elements ensure that player choices are meaningful, constrained by realistic uncertainty and limitations, and connected to observable outcomes that can be discussed and exploited [17]. In addition, the handbook distinguishes adjudication modalities and recommends *analytically-assisted* adjudication when consistency and traceability between decisions and effects are required, particularly in complex domains where outcomes must be interpreted against explicit objectives [17]. These principles provide the methodological basis adopted in this work to structure MARCIM-WG from high-level intent to low-level implementation.

The SERDUX-MARCIM model provides the mathematical and computational foundation for representing cyberattack dynamics in maritime environments. This model combines compartmental approaches inspired by epidemiological modeling with a cyber risk assessment structure to simulate the propagation of cyberattacks across interconnected systems. In particular, it extends classical models by incorporating time-dependent transition rates and variables associated with attacker capabilities, target conditions, and network characteristics, enabling a system-level representation of cyber incidents. The model captures the evolution of nodes through different states (e.g., susceptible, exposed, affected, and recovered), allowing the analysis of how attacks spread, how defensive actions influence system behavior, and how service availability is impacted over time [18]. In the context of MARCIM-WG, this model is not used in its full analytical complexity; instead, it is operationally adapted to support the adjudication process, translating player decisions into parameter variations and producing quantitative outputs that reflect the evolving state of the simulated maritime cyber crisis.

IV. PROPOSAL

A. Overview of MARCIM-WG

MARCIM-WG [20] is a learning-oriented maritime cyberdefense wargame that enables strategic-level participants to rehearse decision-making during a cyber crisis affecting a maritime actor. The proposal combines a physical tabletop (board, tokens, indicators, and special cards) with an analytically-assisted adjudication system implemented in software, so that player choices are translated into model inputs and returned as quantitative outputs that are interpreted collaboratively during facilitation. As illustrated in Fig. 1, MARCIM-WG operationalizes a closed decision–adjudication–feedback loop: players decide and allocate resources on the tabletop, the facilitator/adjudicator encodes those decisions into the software, the simulation produces system-level effects, and the results are fed back to update the game state and structure the after-action discussion.

The wargame is conceived as a continuation and derived product of the MARCIM project [21], building on its maritime cyberdefense modeling-and-simulation foundation. It operationalizes CSA [6], [7] development through structured rounds, escalating threat dynamics, and explicit linkages between actions and consequences.




Figure 1: MARCIM-WG interaction loop model between players, Game Board, and the analytically-assisted adjudication system.

B. High-Level Design Specifications (HLD)

1) *Theme and problem framing:* MARCIM-WG is framed within maritime cyberdefense as a strategic and operational capacity to protect maritime power against cyber incidents. The design responds to a capability gap identified at the strategic level: limited appropriation of incident-response procedures and protocols in maritime cyber crisis contexts, compounded by increasing threat sophistication and the scarcity of specialized training tools for decision-makers in this domain [21].

2) *Wargame type and objectives:* Following the NATO classification, MARCIM-WG is conceived as a learning wargame focused on competence development rather than on validating a specific operational plan [17]. Its general objective is to provide a structured environment where participants analyze the propagation of a cyberattack over a critical maritime network and assess strategic response options. The specific objectives align with the CSA model by targeting: (i) *perception* (identifying relevant cues, anomalies, and milestones), (ii) *comprehension* (interpreting implications and vulnerabilities), and (iii) *projection* (anticipating evolution and planning mitigations) [6], [7].

3) *Core design elements:* The HLD explicitly operationalizes the four essential elements recommended by NATO [17]:

- **Decisions:** players select response actions and allocate limited resources, exploring alternative courses of action under pressure.
- **Friction:** the design introduces constraints, uncertainty, and competing priorities through the game mechanics and role interactions.
- **Consequences:** decisions generate measurable effects on the maritime network and service levels through the adjudication system, enabling structured reflection.
- **Narrative:** a coherent crisis storyline frames the decision context and supports progressive escalation across rounds.

4) *Adjudication approach:* MARCIM-WG adopts an analytically-assisted adjudication method. Player decisions are not resolved only by expert judgement; instead, they are encoded as configurable inputs to a computational model that simulates their effects and returns quantitative outputs (e.g., evolution of node states and service availability) to be interpreted in the game context. Concretely, the adjudication

software is implemented as an operational adaptation of the SERDUX-MARCIM simulation model [18], providing traceability between decisions, model execution, and observed effects on services and nodes. This approach increases consistency and supports results-oriented after-action analysis focused on CSA.

5) *Constraints and assumptions:* At high level, the design acknowledges constraints that condition fidelity and scalability, including computational requirements for dynamic-rate simulation, limits in the number of nodes/links that can be represented, fixed network structure during execution, and abstraction of maritime ecosystem elements to maintain playability and technical feasibility. The design also recognizes limitations associated with data availability for parametrization and the need to interpret results as decision-support learning outputs rather than predictive operational forecasts.

6) *Wargaming team and deliverables:* The HLD defines a multidisciplinary team organized around four methodological phases—design, development, execution, and analysis/reporting—consistent with NATO guidance [17]. Roles include sponsor, game director, designer, facilitator, adjudicator, and analyst functions. The expected deliverable includes a wargame report capturing key findings and lessons to inform future iterations and institutional learning.

C. Low-Level Design Specifications (LLD)

The LLD operationalizes the HLD into detailed rules, mechanics, physical components, and computational integration. The central product is the “Wargame Book”, which structures the game content into: rules (including an ethical/operational confidentiality rule), general characteristics, objectives, roles, actor typology in the narrative, game elements (board, capability tokens, level indicators, BitMarCoins, special cards, dice, and adjudication system), scenario intent and phases, execution phases (preparation; execution across rounds; closure and evaluation), facilitator/adjudicator-only information, and a glossary.

The physical representation of the system under study is materialized through the MARCIM-WG physical gameboard (Fig. 2), which provides a shared visual language to manage state evolution, resources, and decisions during play. The board is updated after each adjudication cycle to reflect the new conditions of the crisis and to sustain discussion and sensemaking at the strategic level.

1) *Adjudication system:* The adjudication system is implemented via the MARCIM-WG software (Fig. 3) as an operational adaptation of the SERDUX-MARCIM model [18]. The software is developed in NetLogo [22], [23] with integrated Python [24] modules, enabling the facilitator/adjudicator to input player decisions, execute simulation runs, and update the tabletop based on model outputs. The LLD also formalizes a competence-based learning structure: three CSA-oriented competences (perception, comprehension, projection) with observable dimensions, associated learning outcomes, and a pre/post instrument to compare initial and achieved levels [6], [8].




Figure 2: Physical MARCIM-WG gameboard used by participants during gameplay to support decision-making, resource allocation, and state updates across adjudication cycles [20].




Figure 3: MARCIM-WG adjudication software [20] (SERDUX-MARCIM operational adaptation) and example of simulation outputs used for tabletop updates.

To support the adjudication process, the underlying SERDUX-MARCIM model is operationally adapted from its original formulation into a decision-support structure that preserves its system-level dynamics while reducing analytical complexity for gameplay purposes. The model is based on a compartmental representation of cyberattack propagation, where network nodes evolve through different states over time according to transition rates influenced by attacker behavior, target conditions, and defensive actions. In MARCIM-WG, this model is integrated through a hierarchical organization of variables derived from the cyber risk approach defined in SERDUX-MARCIM [18]. Specifically, the implementation considers variables up to level 3 of the hierarchy (Table I), where level 0 defines the overall cyber attack severity, level 1 separates likelihood and impact dimensions, and level 2 and level 3 provide progressively detailed factors associated with attacker behavior, target characteristics, defensive controls, and impact assessment.

Within this structure (Table I), player decisions are mapped into modifications of selected level 3 variables, which act as operational inputs to the simulation. It is important to note that, although the original model defines a complete set of variables at this level, the MARCIM-WG implementation excludes specific elements that are not directly relevant to the gameplay abstraction, such as target network traffic, while preserving the remaining factors to ensure representativeness of cyber risk dynamics. During each adjudication cycle, the facilitator encodes player decisions into these variables, executes the simulation, and obtains quantitative outputs such as node-state distributions and service availability levels. These outputs are then interpreted and fed back into the tabletop, ensuring a consistent decision–model–feedback loop that enables participants to observe the systemic consequences of their actions in a dynamic cyber crisis scenario.

2) *Wargame Operational Dynamics:* To provide a clearer understanding of the operational dynamics of MARCIM-WG, the wargame execution is structured into three main phases: preparation, execution, and closure. During the preparation phase, the facilitator defines the scenario configuration, initializes the system state, and distributes initial resources (e.g., capability tokens) among participants to ensure a common baseline for decision-making. This phase also includes the briefing of participants regarding objectives, roles, and rules of interaction.

The execution phase is organized into iterative rounds, each following a consistent decision–adjudication–feedback cycle. In each round, participants assume the role of strategic decision-makers responsible for allocating resources, selecting response actions, and activating available game elements such as capability tokens, BitMarCoins, and special cards. These decisions are made under conditions of uncertainty, resource constraints, and evolving threat dynamics, reflecting the complexity of real-world cyber crisis management.

Once decisions are defined, the facilitator and adjudicator encode them into the simulation environment, where they are translated into parameter modifications of the underlying model. The simulation is then executed, producing quantitative outputs that represent the evolution of the cyberattack, the state of network nodes, and the level of service availability. These results are subsequently interpreted and used to update the gameboard, ensuring that players receive immediate and consistent feedback on the consequences of their actions.

The closure phase focuses on structured reflection and evaluation. During this phase, the outcomes of the simulation are analyzed, and participants engage in a guided discussion to assess the effectiveness of their decisions, identify strengths and weaknesses, and relate the observed dynamics to real-world cyberdefense procedures and protocols. Additionally, the competence-based assessment instrument is applied to evaluate the development of Cyber Situational Awareness (CSA) across its three dimensions: perception, comprehension, and projection.

From a role perspective, MARCIM-WG involves four main functions: (i) players, who act as strategic decision-makers; (ii)

Table I: Hierarchical organization of variables adapted from SERDUX-MARCIM

Level 0	Level 1	Level 2	Level 3
Cyber Risk	Cyber Attack Likelihood	Attacker Likelihood	Attacker Factors (ATF), Vulnerability Factors (VUF)
		Target Likelihood	Likelihood Reduction Controls (ι), Target Cyber Intelligence Capability (TCI), Target Cyber Defense Capability (TCD), Target Support and Sustainability Capability (TSS)
	Cyber Attack Impact	Impact Reduction Controls	Preventive Controls (θ), Corrective Controls (η), Detective Controls (ζ)
		Cyber Attack Degree	Technical Impact (τ), Business Impact (ρ)
		Cyber Attack Duration	—

the facilitator, who guides the process and ensures adherence to the rules; (iii) the adjudicator, who manages the interaction with the simulation model; and (iv) the system itself, which represents the operational environment and enforces the consequences of decisions. This role distribution ensures a clear separation between decision-making, execution, and evaluation processes.

Overall, the structured sequence of phases and roles enables a coherent and reproducible gameplay experience, where decisions are systematically linked to observable outcomes. This design reinforces the learning objectives of the wargame by making explicit the relationship between strategic actions and their systemic effects, thereby supporting the development of Cyber Situational Awareness in complex environments.

D. Application to a Maritime Cyberdefense Crisis Scenario

The proposal is instantiated through a fully fictional maritime cyberdefense crisis scenario that provides narrative and technical coherence for gameplay. The scenario is dynamic: its trajectory depends on participant decisions under uncertainty and strategic pressure, while the adjudication system computes consequences in terms of cyberattack progression, impact on the target network, and institutional response capacity [21], [18].

Participants influence the scenario through round-based control elements: (i) capability tokens allocated across the target's defensive capacities, (ii) BitMarCoins representing a constrained resource associated with crisis-specific decisions, and (iii) special cards that introduce discrete actions and structured frictions. In the first round, the facilitator distributes capability tokens uniformly across the target capacities to support familiarization; in subsequent rounds, allocation choices and the activation of additional elements depend on the players' strategic decisions. To reflect escalation, attacker and cyberattack parameters increase progressively across rounds, enabling the model to represent a transition from an initial threat into destructive effects executed by a sophisticated adversary. The scenario configuration includes initial network conditions and key parameters governing state evolution (e.g., propagation and resilience-loss dynamics), so that repeated decision-adjudication cycles expose players to measurable cause-effect relationships that support CSA development and structured after-action reflection.

V. VALIDATION AND RESULTS

To verify the formative impact and functional coherence of MARCIM-WG, two complementary validations were conducted. First, a *conceptual validation* assessed whether the wargame and its adjudication system respond coherently to different decision patterns under three scenario configurations (pessimistic, neutral/most likely, and optimistic). Second, a *CSA competency and learning-outcome validation* evaluated the extent to which MARCIM-WG contributes to strategic Cyber Situational Awareness (CSA) development through a structured assessment instrument and a comparative strategy with an equivalent control group.

A. Conceptual validation (scenario-based execution)

Conceptual validation was conducted by executing MARCIM-WG under three scenario configurations—pessimistic, neutral (most likely), and optimistic—to assess whether the adjudication logic and the resulting system behavior are sensitive to different strategic decision patterns. Fig. 4 summarizes the scenario-based validation approach used during the operational trials. The outcomes were generated through the analytically-assisted adjudication process (operational adaptation of the SERDUX-MARCIM model) and interpreted in terms of service availability and network degradation.




Figure 4: Operational validation of MARCIM-WG through three scenarios (pessimistic, neutral/most likely, optimistic)[20].

The pessimistic scenario reflected limited planning and delayed or erratic use of special cards, resulting in rapid system degradation, a drop of service level below 35%, and 224 destroyed nodes, with no effective recovery. The neutral (most likely) scenario represented a tactical response without strategic articulation; despite using special cards, actions were applied in a poorly coordinated manner and the system maintained around 50% of active services, but with 175 destroyed

nodes and a degraded network. In contrast, the optimistic scenario combined structured planning, timely activation of special cards, and coherent investment of capability tokens, preserving more than 80% of active services and limiting destruction to 65 nodes. Collectively, these results support that MARCIM-WG is decision-sensitive and that the integration of narrative, physical resources, and computational adjudication yields coherent dynamics for training and discussion.

B. CSA competency and learning-outcome validation

1) *Purpose and validation design:* To empirically verify the contribution of MARCIM-WG to CSA development, a comparative validation strategy was implemented using an equivalent control group. The purpose was to contrast the appropriation of key CSA concepts between participants who did not play the wargame and those who completed a controlled MARCIM-WG session. The validation followed a basic quasi-experimental design with post-test measurement between groups, treating the wargame experience as the independent variable and the measured competency attainment as the dependent variable.

2) *Participants profile:* Both the control group and the intervention group were composed of active-duty Colombian Armed Forces officers, selected to ensure technical-operational equivalence and a comparable strategic background. The selection criteria included: (i) institutional affiliation as active officers (Navy, Army, or Air Force); (ii) at least 20 years of professional experience in operational, strategic, or institutional support roles; and (iii) prior formal education (any level) related to cybersecurity, cyberdefense, or military strategy. Additional criteria ensured familiarity with cyber risk and incident management, as well as functional understanding of maritime power (doctrine, planning, or professional experience). This profile sought to guarantee that participants had the conceptual and strategic baseline required to interact meaningfully with the wargame.

3) *Competency and learning-outcome assessment instrument:* The assessment instrument was designed as a formative tool with a comparative function to measure the development (or improvement) of the three CSA-oriented competencies targeted by MARCIM-WG, aligned with the three CSA phases: perception, comprehension, and projection [6], [8]. It consists of 25 questions mapped to the three competencies and their corresponding learning outcomes (LOs), enabling aggregation at two levels: (i) overall performance and (ii) performance by competency and LO. While the instrument is suitable for pre/post applications, the present validation implemented it as a post-test comparison between equivalent groups (control vs. intervention) to isolate the effect of the wargame within the constraints of the validation session.

4) *Results and discussion:* The competency validation session was conducted on July 10, 2025, at the Escuela Superior de Guerra “General Rafael Reyes Prieto” (Bogotá D.C., Colombia). First, the instrument was applied to a control group of eight officers who had not participated in MARCIM-WG. Subsequently, four officers with the same profile completed

a controlled MARCIM-WG session and answered the same instrument immediately after finishing the game. Fig. 5 depicts the competency-validation session context associated with this comparative assessment.




Figure 5: Competency and learning-outcome validation of MARCIM-WG (CSA-focused assessment)[20].

Table II summarizes the comparative results. At the global level, the intervention group achieved 91.2% correct answers versus 57.2% in the control group, yielding a reported improvement of +34.0 percentage points. By competency, the largest gain was reported for Competency 2 (integrated comprehension of cyber-crisis scenarios), followed by Competency 1 (strategic perception of the environment), and Competency 3 (strategic foresight - future scenarios).

Table II: Comparative results of competency and learning-outcome validation (control vs. intervention).

Competency / LO	Ctrl	Intv	Diff
Overall result	57.2	91.2	+34.0
Competency 1 – Strategic perception	66.6	88.8	+29.2
LO 1.1 Identify critical assets	70.0	100.0	+30.0
LO 1.2 Recognize active threats	54.3	100.0	+45.7
LO 1.3 Assess cyber risk level	54.6	66.6	+12.0
Competency 2 – Integrated comprehension	61.9	97.5	+35.54
LO 2.1 Analyze attack evolution	71.8	100.0	+28.2
LO 2.2 Evaluate cyber capabilities	44.0	100.0	+56.0
LO 2.3 Recognize crisis phases	71.5	100.0	+28.5
LO 2.4 Apply ISO/IEC 27035 principles	60.0	100.0	+40.0
LO 2.5 Analyze strategic implications	62.5	87.5	+25.0
Competency 3 – Strategic foresight	78.3	89.5	+11.2
LO 3.1 Formulate strategic hypotheses	87.5	100.0	+12.5
LO 3.2 Evaluate effects of decisions	59.3	68.7	+9.3
LO 3.3 Reflect on operational/doctrinal implications	88.0	100.0	+12.0

Source: own elaboration based on the validation session results [20].

At the LO level, all measured outcomes improved, with reported gains ranging from +9.3 to +56.0 points. The largest single improvement corresponded to LO 2.2 (evaluation of cyber capabilities), rising from 44.0% to 100.0% (+56.0). Other notable gains included LO 1.2 (recognition of active threats), from 54.3% to 100.0% (+45.7), and LO 2.4 (application of ISO/IEC 27035 principles), from 60.0% to 100.0% (+40.0). The lowest LO-level gain was observed in LO 3.2 (evaluation of decision effects), from 59.3% to 68.7% (+9.3), suggesting that projection-oriented reasoning may require additional repetitions, more time for reflection, or complementary instructional scaffolding.

Overall, the CSA-focused results show that MARCIM-WG strengthens perception, comprehension, and projection, with strong effects on comprehension-related outcomes. However,

the evidence should be interpreted with caution due to the limited sample size and post-test-only, between-groups design; future replications with larger cohorts would allow stronger inference and clearer characterization of retention.

VI. CONCLUSIONS

This paper presented MARCIM-WG, a learning-oriented maritime cyberdefense wargame designed to strengthen strategic Cyber Situational Awareness (CSA) through a hybrid approach that combines a physical tabletop experience with analytically-assisted adjudication supported by computational simulation. The proposal operationalizes meaningful decision cycles under friction, links actions to measurable consequences, and leverages a coherent narrative to support structured reflection and institutional learning.

The validation results indicate that MARCIM-WG contributes to CSA development across the three targeted competencies (perception, comprehension, and projection). The most substantial improvements were observed in comprehension-related outcomes, particularly those associated with evaluating cyber capabilities and interpreting crisis dynamics, which suggests that the wargame effectively supports higher-order reasoning that connects technical signals with strategic decision-making. At the same time, the comparatively smaller gains in projection-oriented outcomes reinforce the need for repeated gameplay iterations and additional instructional scaffolding to consolidate anticipatory reasoning in complex cyber crises.

A key practical contribution of MARCIM-WG is that the adjudication system enables the use of a rigorous mathematical simulation model without transferring its full complexity to the players. By encapsulating the underlying dynamics within the adjudication software—and exposing participants only to decision levers and interpretable outputs—the approach proved viable for training and assessment purposes. This design choice also indicates broader applicability: the same adjudication logic, grounded on a compartmental and agent-based simulation core, can be adapted to non-maritime cybersecurity and cyberdefense scenarios by modifying the scenario configuration, network representation, and decision levers while preserving the decision–consequence structure of the wargame.

The main limitations of this study are the reduced sample size and the post-test-only comparison design. Future work should replicate the assessment with larger cohorts, incorporate repeated-measures designs to evaluate retention over time, and refine projection-oriented learning elements (e.g., additional injects, longer decision windows, and more structured after-action prompts) to improve anticipatory reasoning and transfer of learning.

Supporting documentation, scenario assets, datasets, and implementation are available at <https://github.com/diegoca-buya/SERDUX-MARCIM>.

REFERENCES

- [1] United Nations Conference on Trade and Development - UNCTAD, "Review of maritime transport 2024," https://unctad.org/system/files/official-document/rmt2024_en.pdf, United Nations Conference on Trade and Development. UNCTAD, Tech. Rep., 2024.

- [2] J. I. Alcaide and R. G. Llave, "Critical infrastructures cybersecurity and the maritime sector," *Transportation Research Procedia*, vol. 45, pp. 547–554, 2020.
- [3] S. Symes, E. Blanco-Davis, T. Graham, J. Wang, and E. Shaw, "Cyber-attacks on the maritime sector: a literature review," *Journal of Marine Science and Application*, pp. 1–18, 2024.
- [4] I. Mraković and R. Vojinović, "Maritime cyber security analysis – how to reduce threats?" *Transactions on Maritime Science*, vol. 8, no. 1, pp. 132–139, 2019.
- [5] M. S. Karim, "Maritime cybersecurity and the imo legal instruments: Sluggish response to an escalating threat?" *Marine Policy*, vol. 143, p. 105138, 2022.
- [6] M. R. Endsley, "Toward a theory of situation awareness in dynamic systems," *Human Factors*, vol. 37, no. 1, pp. 32–64, 1995.
- [7] U. Franke and J. Brynielsson, "Cyber situational awareness—a systematic review of the literature," *Computers & Security*, vol. 46, pp. 18–31, 2014.
- [8] C. L. Paul and K. Whitley, "A taxonomy of cyber awareness questions for the user-centered design of cyber situation awareness," in *LNCS*. Springer, Berlin, Heidelberg, 2013, vol. 8030, pp. 145–154.
- [9] O. Jacq, D. Brosset, Y. Kermarec, and J. Simonin, "Cyber attacks real time detection: towards a cyber situational awareness for naval systems," in *2019 International Conference on Cyber Situational Awareness, Data Analytics and Assessment (Cyber SA)*, 2019, june 1.
- [10] D. J. Bodeau, C. D. Mccollum, and D. B. Fox, "Cyber wargaming: framework for enhancing cyber wargaming with realistic business context," MITRE, Tech. Rep., 2018, <http://www.mitre.org/HSEDI>.
- [11] J. Curry and N. Drage, "Developments in state level cyber wargaming," in *ACM International Conference Proceeding Series*, 2018.
- [12] M. G. Weiner, "War gaming methodology," https://doi.org/10.1163/9789087903107_006, 1959.
- [13] B. Onduto, "Gamification of cyber security awareness – a systematic review of games," Master's thesis, University of Turku, 2021, master of Science in Technology Thesis. Computing, Faculty of Technology.
- [14] D. E. Cabuya-Padilla and C. A. Castaneda-Marroquin, "Marco de referencia para el modelamiento y simulación de la ciberdefensa marítima - marcim: estado del arte y metodología," *DYNA*, vol. 91, no. 231, pp. 169–179, 2024.
- [15] D. E. Cabuya-Padilla, C. F. Alvarado Carvajal, R. A. Carrascal Ortiz, J. M. Riola Rodríguez, C. H. Fajardo-Toro, and S. P. Escandon Bernal, "Ciberseguridad y ciberdefensa marítima: análisis bibliométrico años 1990 – 2021," *RISTI - Revista Iberica de Sistemas e Tecnologias de Informacao*, vol. 49, pp. 197–210, 2022.
- [16] D. E. Cabuya-Padilla, D. Díaz-López, and C. Castaneda-Marroquin, "Hybrid tabletop exercise (ttx) based on a mathematical simulation-based model for the maritime sector," in *Actas de las X Jornadas Nacionales de Investigación en Ciberseguridad: Zaragoza, 4 a 6 de junio de 2025*, 2025, pp. 37–44, <https://2025.jnic.es/>.
- [17] Allied Command Transformation, "Nato wargaming handbook," <https://paxsims.wordpress.com/wp-content/uploads/2023/09/nato-wargaming-handbook-202309.pdf>, 2023.
- [18] D. E. Cabuya-Padilla, D. Díaz-López, J. Martínez-Páez, L. Hernández, and C. Castaneda-Marroquin, "Serdex-marcim: Maritime cyberattack simulation using dynamic modeling, compartmental models in epidemiology and agent-based modeling," *International Journal of Information Security*, vol. 24, no. 3, p. 122, 2025.
- [19] I. Mayer, H. Warmelink, and Q. Zhou, "The utility of games for society, business, and politics," in *The Wiley Handbook of Learning Technology*. Wiley, 2016, pp. 406–435.
- [20] D. E. Cabuya-Padilla, "MARCIM-WG: Juego de guerra de ciberdefensa marítima para la apropiación estratégica de respuestas ante crisis cibernéticas," Monografía de maestría, Escuela Superior de Guerra "General Rafael Reyes Prieto", Bogotá D.C., Colombia, 2025, maestría en Ciberseguridad y Ciberdefensa.
- [21] —, "Marco de referencia para el modelamiento y simulación de la ciberdefensa marítima a nivel estratégico – marcim," Ph.D. dissertation, Escuela Naval de Cadetes "Almirante Padilla", 2024, [Tesis Doctoral].
- [22] U. Wilensky, "Netlogo," <https://ccl.northwestern.edu/netlogo/>, 2016.
- [23] U. Wilensky and W. Rand, *An Introduction to Agent-Based Modeling: Modeling Natural, Social, and Engineered Complex Systems with Net-Logo*. MIT Press, 2015.
- [24] Python Software Foundation, "Python," <https://www.python.org/>, 2023.

alicIA: Un asistente docente basado en GPT personalizado con enfoque socrático para la enseñanza de criptografía

Vanessa Daza
Universitat Pompeu Fabra
Roc Boronat 138
vanessa.daza@upf.edu

Carla Ràfols
Universitat Pompeu Fabra
Roc Boronat 138
carla.rafols@upf.edu

Resumen—La enseñanza de la criptografía plantea desafíos pedagógicos singulares, derivados de su alto nivel de abstracción matemática y de la precisión requerida en las definiciones formales de seguridad. Presentamos alicIA, un asistente docente construido como GPT personalizado sobre ChatGPT, diseñado para la asignatura *Cryptography and Security* (CS2526) de la Universitat Pompeu Fabra. A diferencia de los LLM genéricos, alicIA integra los materiales oficiales del curso mediante *retrieval-augmented generation* (RAG) y se rige por once reglas pedagógicas, agrupadas en bloques temáticos, que implementan un enfoque socrático: no proporcionar soluciones completas, exigir intento previo y priorizar la notación del curso.

Una encuesta voluntaria a $N = 21$ estudiantes muestra una valoración positiva del enfoque socrático ($\bar{x} = 3,90/5$), alta percepción de fiabilidad ($\bar{x} = 4,06/5$) y experiencia global favorable ($\bar{x} = 3,86/5$), con el 76 % recomendando una herramienta similar en todas sus asignaturas. El análisis cualitativo revela una *ecología de herramientas*: el 57 % combinó alicIA con ChatGPT genérico, asignando al asistente especializado un nicho pedagógico diferenciado. Documentamos el diseño, la integración en el plan docente y las lecciones extraídas, contribuyendo al debate sobre el uso responsable de la IA generativa en la formación en ciberseguridad.

Index Terms—inteligencia artificial en educación, GPT personalizado, enfoque socrático, criptografía, innovación docente, guardrails pedagógicos, formación en ciberseguridad

Tipo de contribución: Formación e innovación educativa

I. INTRODUCCIÓN

La criptografía es una disciplina que combina fundamentos matemáticos abstractos (aritmética modular, teoría de grupos, curvas elípticas) con definiciones formales de seguridad basadas en experimentos y ventajas computacionales. Esta naturaleza dual hace que los estudiantes frecuentemente se enfrenten a dos tipos de dificultades: por un lado, la manipulación algebraica necesaria para operar con las construcciones criptográficas; por otro, la comprensión profunda de qué significa que un esquema sea “seguro” y cómo se formaliza esta noción mediante experimentos como IND-CPA o IND-CCA [1]. En este contexto, los experimentos de seguridad son definiciones formales que modelan las capacidades de un adversario: IND-CPA (*indistinguishability under chosen-plaintext attack*) exige que ningún adversario eficiente pueda distinguir cifrados de dos mensajes elegidos por él; IND-CCA añade acceso a un oráculo de descifrado; KR (*key recovery*) modela la recuperación directa de la clave; e IND-CO (*ciphertext-only*) restringe al adversario a observar únicamente

textos cifrados. Estas nociones formales constituyen el núcleo conceptual de CS2526.

La aparición de modelos de lenguaje de gran tamaño (LLMs) ha abierto nuevas posibilidades para el apoyo docente personalizado y escalable. Sin embargo, el uso directo de LLMs genéricos plantea riesgos documentados: alucinaciones, provisión de soluciones completas que desincentivan el pensamiento crítico, y falta de alineación con el temario específico [2], [3]. Una revisión sistemática reciente [4] advierte además del riesgo de sobredependencia cognitiva cuando los sistemas de diálogo con IA proporcionan respuestas directas sin exigir elaboración por parte del estudiante. Estos riesgos son especialmente graves en criptografía, donde, a diferencia de la programación, en que el código se puede ejecutar, las demostraciones y razonamientos requieren verificación formal por parte del estudiante.

Para situar la propuesta, en este trabajo entendemos por LLM un modelo generativo de lenguaje de propósito general capaz de mantener diálogo en lenguaje natural; por *retrieval-augmented generation* (RAG), un mecanismo en el que el sistema recupera primero fragmentos relevantes de una base documental antes de responder; por *guardrails*, restricciones explícitas que acotan el tipo de ayuda que puede ofrecer el asistente; y por *enfoque socrático*, una estrategia de andamiaje basada en preguntas, pistas y reformulaciones, en lugar de soluciones completas. Estos cuatro elementos estructuran el diseño de alicIA y permiten distinguirla de un uso genérico de ChatGPT.

Motivados por estos desafíos, diseñamos alicIA (*Artificial Intelligence for Cryptography and security, Instructional Assistant*), un GPT personalizado con enfoque pedagógico socrático, integrado formalmente en la asignatura *Cryptography and Security* (CS2526) de la UPF, una asignatura obligatoria de 5 ECTS para más de 100 estudiantes de tercer curso de los grados de Ingeniería Informática, Telemática y Ciencia de Datos.

I-A. Objetivos docentes

El diseño de alicIA se guía por cuatro objetivos docentes concretos:

1. **Fomentar el razonamiento formal y la autonomía** del estudiantado en la resolución de ejercicios de criptografía, evitando la copia directa de soluciones.

2. **Ofrecer feedback inmediato y alineado con los apuntes oficiales**, reduciendo el riesgo de desajustes conceptuales habituales al usar LLMs genéricos.
3. **Disminuir la brecha de intimidación** asociada a una asignatura percibida como matemáticamente exigente, proporcionando un espacio seguro para preguntar y equivocarse.
4. **Explorar la viabilidad de un asistente socrático reutilizable** en otras asignaturas de ciberseguridad, documentando explícitamente las decisiones de diseño y sus efectos percibidos.

I-B. Contribuciones

Las contribuciones de este trabajo son: (1) el diseño de un GPT personalizado con once reglas pedagógicas socráticas para criptografía, agrupadas en bloques temáticos; (2) su integración formal en el plan docente; (3) una comparativa cualitativa con ChatGPT genérico; (4) resultados cuantitativos y cualitativos de una encuesta a $N = 21$ estudiantes que validan los objetivos propuestos; y (5) identificación de cinco patrones temáticos sobre adopción, uso combinado con herramientas genéricas, tensión entre enfoque socrático y deseo de respuestas directas, y riesgos emergentes de sustitución de la asistencia presencial.

El resto del artículo se organiza como sigue. La Sección II revisa el trabajo relacionado en asistentes con *guardrails*, enfoque socrático con LLMs e IA en educación en ciberseguridad. La Sección III describe el diseño de alicIA, sus reglas pedagógicas y su integración en el curso. La Sección IV presenta una comparativa cualitativa con ChatGPT genérico. La Sección V detalla la metodología de evaluación y la Sección VI los resultados de la encuesta. La Sección VII discute las contribuciones, limitaciones y lecciones para la docencia en ciberseguridad, y la Sección VIII concluye el trabajo.

II. TRABAJO RELACIONADO

Esta sección revisa tres líneas de trabajo progresivamente más cercanas a nuestra contribución: primero, asistentes con *guardrails* en programación, donde la verificación de errores es automática; después, enfoques socráticos con LLMs en diversas disciplinas; y finalmente, el uso incipiente de IA en la educación en ciberseguridad. Con este recorrido queda clara la brecha que alicIA pretende cubrir.

II-A. Asistentes con *guardrails* en informática

Liffiton et al. [2] presentaron CodeHelp, una herramienta con *guardrails* para asistencia en programación sin revelar soluciones, desplegada con 52 estudiantes durante 12 semanas. Los estudiantes valoraron su disponibilidad y su utilidad como complemento al profesorado. Kazemitabaar et al. [3] desarrollaron CodeAid a mayor escala (700 estudiantes, 12 semanas, 8.000 interacciones), con respuestas correctas en aproximadamente el 90 % de los casos. CS50.ai [5] integra una suite completa de herramientas de IA para el curso introductorio de programación de Harvard.

II-B. Enfoque socrático con LLMs

Más allá de limitar la información, otra línea de trabajo explora cómo guiar al estudiante mediante el diálogo socrático. Liu et al. [6] propusieron SocraticLM, que emplea un *pipeline* multi-agente para generar 35.000 diálogos socráticos sobre problemas matemáticos, superando a GPT-4 en un 12 % en calidad pedagógica. Favero et al. [7] evaluaron chatbots socráticos para pensamiento crítico mediante *fine-tuning* de Llama-2 con preguntas de pensamiento guiado, mostrando mayor *engagement* y comprensión que las respuestas directas. En programación, Gupta et al. [8] describen Saksham AI, cuya interfaz conversacional (Disha) implementa un enfoque socrático; sus resultados reportan mejoras percibidas en razonamiento y en hábitos de resolución de problemas frente a asistentes genéricos.

Recientemente, Tufino y Gregorcic [9] han demostrado la viabilidad de la *ingeniería de roles* (*role engineering*) para transformar LLMs genéricos en tutores socráticos especializados en física, utilizando *scripts* pedagógicos detallados sobre Gemini Gems. Su trabajo confirma que un modelo “guionizado” genera diálogo socrático en contraste con el mismo modelo sin instrucciones, que tiende a dar soluciones directas. Esta observación es consistente con nuestro diseño de alicIA, aunque aplicado a un dominio distinto (criptografía) y con una arquitectura diferente (Custom GPT con RAG).

No obstante, la evidencia sobre la eficacia del enfoque socrático con LLMs no es unánime. Blasco y Charisi [10] condujeron un experimento de campo con un tutor socrático basado en GPT-4 en secundaria, encontrando mayor frecuencia de interacción pero sin mejoras medibles en el aprendizaje, y con percepciones de menor utilidad respecto a un tutor de respuesta directa. Este resultado subraya la importancia de contextualizar el enfoque socrático dentro de un diseño pedagógico integral, como el que proponemos con alicIA.

II-C. IA en educación en ciberseguridad

Frente a la abundancia de trabajos en programación y matemáticas, el uso de IA en la enseñanza de ciberseguridad está considerablemente menos explorado. Estudios recientes [11], [12] analizan percepciones de estudiantes y docentes sobre ChatGPT en formación universitaria, reportando impacto percibido positivo pero con brechas de capacitación y preocupaciones éticas. Segarra et al. [13] presentan una experiencia integrando ChatGPT en docencia universitaria, evaluada mediante el modelo TAM (*Technology Acceptance Model*), que mide la utilidad percibida y la facilidad de uso como predictores de la adopción tecnológica. Sus resultados reportan valoraciones positivas en ambas dimensiones, pero también señalan riesgos de dependencia y episodios de inexactitud en las respuestas del modelo.

II-D. Brecha identificada

Los trabajos previos se concentran en programación, donde los errores del LLM se detectan mediante ejecución, o en disciplinas como física [9] donde las respuestas pueden verificarse experimentalmente. En criptografía, la verificación requiere razonamiento formal sobre definiciones de seguridad, haciendo los *guardrails* aún más críticos. No existe trabajo publicado, hasta donde hemos podido verificar, sobre un GPT

socrático para criptografía, menos aún en el contexto universitario español. alicIA se sitúa, por tanto, como una translación de los guardrails de la asistencia en programación a un dominio donde no se puede “ejecutar” (las demostraciones de seguridad), y como una adaptación del socratismo LLM al contexto concreto de la criptografía de grado en España.

III. DISEÑO DE ALICIA

III-A. Arquitectura y materiales

alicIA está construida como un GPT personalizado (*Custom GPT*) sobre la plataforma de ChatGPT de OpenAI, accesible públicamente¹. Este formato permite definir instrucciones de sistema y adjuntar documentos que el modelo utiliza como base de conocimiento mediante *Retrieval-Augmented Generation* (RAG): cuando el estudiante formula una pregunta, el sistema recupera automáticamente los fragmentos más relevantes de los documentos adjuntos y los incorpora al contexto del modelo antes de generar la respuesta, reduciendo así el riesgo de alucinaciones y mejorando la alineación con el material del curso.

En la práctica, la especialización de alicIA no se basa en un reentrenamiento del modelo, sino en la combinación de instrucciones de sistema y recuperación documental sobre los materiales oficiales de la asignatura. Ante cada consulta, el sistema incorpora al contexto de generación los fragmentos más relevantes de esos documentos, de modo que la respuesta quede anclada en la terminología, notación y alcance del curso. Esta solución se eligió frente a alternativas más complejas por su rapidez de despliegue, facilidad de iteración docente y adopción inmediata por parte del estudiantado.

Se eligió la plataforma de Custom GPTs de OpenAI por tres razones prácticas: (i) no requiere infraestructura institucional ni costes de despliegue para el profesorado; (ii) permite iterar rápidamente sobre las instrucciones de sistema y los documentos adjuntos; y (iii) ofrece acceso inmediato al estudiantado, que ya disponía mayoritariamente de cuentas de ChatGPT. Estas ventajas se ponderaron frente a la limitación principal: la dependencia de una plataforma comercial y los límites de uso de la versión gratuita (véase T4 en la Sección VI-D).

Los materiales incorporados incluyen los apuntes oficiales completos del curso, que cubren: introducción a la seguridad y parámetro λ ; criptografía simétrica (OTP, cifrados de bloque y flujo, modos de operación, definiciones formales mediante experimentos KR, IND-CO, IND-CPA e IND-CCA); funciones hash; fundamentos de criptografía asimétrica (aritmética modular, grupos, cuerpos finitos); cifrado de clave pública (RSA, ElGamal, Diffie-Hellman); firmas digitales; y compartición de secretos (Shamir).

III-B. Reglas pedagógicas

Las instrucciones de sistema de alicIA comprenden las siguientes reglas

Enfoque socrático e integridad académica. alicIA nunca proporciona la solución final ni un desarrollo paso a paso copiable. Ofrece un máximo de 1–2 pistas por turno, breves recordatorios teóricos y preguntas guía. Si el estudiante pide “la respuesta”, alicIA rechaza educadamente y solicita un paso intermedio concreto.

Alineación con el curso. alicIA prioriza la notación, terminología y métodos de los apuntes. Si carece de una definición necesaria, la solicita al estudiante. Si una pregunta excede el temario, la etiqueta como “fuera del temario”.

Entrada mínima y diagnóstico. Antes de asistir, alicIA exige: (i) el enunciado completo, (ii) el intento del estudiante (aunque parcial), y (iii) el punto exacto de atasco. Esta regla obliga al estudiante a articular su comprensión, un principio socrático fundamental.

Aprendizaje por analogía. Ante un bloqueo conceptual, alicIA propone un ejemplo análogo más simple sin resolverlo, pide al estudiante que complete un paso concreto, y mapea explícitamente el ejemplo al ejercicio original.

Revisión de errores. alicIA revisa cálculos y demostraciones señalando *dónde* empieza el error, sin corregirlo. Prioriza errores típicos de criptografía: reglas incorrectas del experimento, condición de longitud omitida, confusión probabilidad/ventaja, reutilización de claves en OTP, pasos erróneos en aritmética modular, etc.

Multilingüismo. alicIA responde exclusivamente en el idioma del estudiante (catalán, castellano o inglés), sin mezclar idiomas.

Uso de SageMath. Cuando es necesaria verificación computacional, alicIA proporciona esqueletos de código dejando las partes clave para el estudiante.

Asistencia responsable: alicIA no ayuda con actividades ilícitas reales (intrusión en sistemas, escritura de exploits, ejecución de ataques contra servicios en producción); si un ejercicio trata sobre ataques (e.g., razonamiento sobre maleabilidad o padding oracle), la discusión se mantiene estrictamente en el marco académico, y se pide al estudiante que articule el paso clave por sí mismo.

Notación y formato: alicIA utiliza LaTeX para toda notación matemática y criptográfica ($\backslash (\dots \backslash)$ para expresiones en línea, $\backslash [\dots \backslash]$ para bloques), manteniendo respuestas breves, claras y bien estructuradas.

Estructura de respuesta por defecto: cada respuesta sigue un esquema fijo de cuatro partes:

- contexto (una frase identificando el tipo de problema),
- diagnóstico (qué ha intentado el estudiante y dónde se ha atascado),
- plan (1–2 ideas clave a aplicar, sin desarrollar), y
- siguiente paso (una pregunta concreta o micro-tarea que el estudiante puede abordar de inmediato).

III-C. Integración en el curso

alicIA fue presentada el primer día de clase como componente formal de la metodología docente. La asignatura CS2526 (5 ECTS, 125 horas) se organiza en cuatro componentes: clases magistrales, prácticas de problemas, seminarios con laboratorios, y sesiones no presenciales. alicIA se posiciona en este último componente, como herramienta de apoyo al trabajo autónomo del estudiantado.

Se comunicaron tres directrices de uso: (1) *usar para*: pistas, verificación de pasos, explicaciones alternativas, ejercicios adicionales; (2) *no usar para*: generar soluciones irreproducibles; (3) *regla de prioridad*: si alicIA contradice los apuntes, los apuntes prevalecen. Esta última directriz es especialmente relevante ante el riesgo de alucinaciones en demostraciones

¹<https://chatgpt.com/g/g-695e76b604b881918019470f4389d319-alicia>

Tabla I
COMPARATIVA CHATGPT GENÉRICO VS. ALICIA

Dimensión	ChatGPT genérico	alicIA
Corrección	Alta (not. estándar)	Alta (alineada apuntes)
Enfoque	Respuesta directa	Socrático: 1–2 pistas
Notación	Libros de texto	Específica del curso
Pens. crítico	Bajo (copiable)	Alto (razon. propio)
Sobredependencia	Riesgo alto	Riesgo bajo

criptográficas, y establece un marco de confianza verificable entre el estudiantado y la herramienta.

IV. COMPARATIVA: CHATGPT GENÉRICO VS. ALICIA

Para ilustrar las diferencias de comportamiento, formulamos las mismas preguntas a ambos sistemas y analizamos las respuestas según cuatro dimensiones: corrección, enfoque pedagógico, alineación con el curso y fomento del pensamiento crítico. Esta comparativa tiene un propósito ilustrativo y pedagógico, y no constituye una evaluación sistemática ni un benchmark experimental entre modelos.

Pregunta conceptual: “¿Qué es la seguridad semántica y cómo se relaciona con IND-CPA?” ChatGPT genérico proporcionó una explicación completa y correcta con notación estándar de libro de texto. alicIA preguntó primero qué experimento del curso creía el estudiante más relacionado, y solo tras la respuesta ofreció una pista sobre la conexión con IND-CPA usando la notación de los apuntes.

Resolución de problemas: “Demuestra que RSA es determinista”. ChatGPT genérico presentó la demostración completa paso a paso, copiable directamente. alicIA solicitó el enunciado exacto, preguntó qué propiedades de RSA conocía el estudiante, y ofreció una pista: “¿qué teorema de los apuntes relaciona m^{ed} con m módulo n ?”.

Error conceptual: “¿Puedo usar ElGamal con el grupo Z_n^* donde n es compuesto?” ChatGPT señaló problemas de seguridad sin explorar las implicaciones. alicIA devolvió la pregunta: “¿Qué propiedades necesita el grupo para que la seguridad se sostenga? ¿Qué pasa si tiene orden compuesto?”.

La Tabla I resume las diferencias observadas. El patrón común es que ChatGPT genérico responde *correctamente pero de forma copiable*, mientras que alicIA genera un diálogo que obliga al estudiante a razonar cada paso.

V. METODOLOGÍA DE EVALUACIÓN

La evaluación inicial de alicIA se realizó mediante una encuesta anónima en línea, administrada a través de Google Forms y dirigida a todo el estudiantado matriculado en CS2526 durante el curso 2025–26. La participación fue completamente voluntaria, no vinculada a la evaluación de la asignatura, y no se recogieron direcciones de correo ni datos identificativos. La encuesta estuvo abierta en la penúltima semana de clase, antes de disponer de las calificaciones finales del curso, de modo que los resultados recogen percepciones de uso e impacto percibido, pero no permiten todavía inferir efectos sobre el rendimiento académico.

En consecuencia, esta primera evaluación debe interpretarse como un estudio descriptivo y exploratorio centrado en percepciones de uso, utilidad y encaje pedagógico, y no como una estimación causal del impacto de alicIA sobre el aprendizaje. Asimismo, en esta fase no se recopilaban logs de interacción

ni otros datos personales adicionales más allá de las respuestas anónimas al cuestionario.

El cuestionario incluyó tres bloques: (i) ítems sobre frecuencia y patrones de uso (tipo de tareas, momento del día); (ii) una batería de ítems tipo Likert (1–5) sobre la percepción del impacto de alicIA en la comprensión de conceptos, la utilidad del enfoque socrático, la fiabilidad de las respuestas, la preferencia frente a LLMs genéricos, la complementariedad con las clases y la experiencia global; y (iii) preguntas abiertas para recoger comentarios cualitativos sobre fortalezas, limitaciones y sugerencias de mejora.

Se obtuvieron $N = 21$ respuestas de más de 100 estudiantes matriculados. Aunque esta tasa de respuesta ($\approx 20\%$) limita la representatividad estadística y puede presentar sesgo de autoselección hacia usuarios más activos, permite obtener indicadores exploratorios sobre adopción, percepción de utilidad y posibles tensiones pedagógicas asociadas al uso de un asistente socrático basado en GPT. Cabe señalar que tres respuestas presentaron errores de formato en los ítems de fiabilidad y complementariedad (selección de etiqueta de columna en lugar de valor numérico), reduciéndose la muestra válida a $N = 18$ para esos ítems.

Para variables ordinales (frecuencia de uso, ítems Likert), se reportan medianas, rangos intercuartílicos y distribuciones de frecuencia. Para las escalas Likert, siguiendo recomendaciones metodológicas [14], [15], se reportan también medias y desviaciones estándar como resumen descriptivo, reconociendo el debate sobre el tratamiento paramétrico de escalas ordinales. No se realizaron tests inferenciales dada la naturaleza exploratoria del estudio y el tamaño muestral. El análisis cualitativo de los 21 comentarios abiertos se realizó mediante codificación temática [16], identificando patrones recurrentes en fortalezas, limitaciones y tensiones percibidas.

VI. RESULTADOS DE LA ENCUESTA

VI-A. Adopción y patrones de uso

La mayoría de encuestados (42,9 %) declaró haber utilizado alicIA “varias veces al mes”, seguida de un 28,6 % que la usó “1–2 veces en total”, un 23,8 % que la consultó semanalmente y un 4,8 % que la empleó varias veces por semana. Ningún encuestado declaró no haberla usado nunca. Esta distribución sugiere que, en su despliegue inicial, alicIA se consolidó sobre todo como recurso de apoyo puntual al trabajo autónomo, más que como herramienta de uso diario intensivo.

Los usos principales (respuesta múltiple) se muestran en la Figura 1: ayuda con ejercicios y problemas (85,7 %), aclaración de dudas teóricas (71,4 %), preparación de exámenes (52,4 %), resolución de dudas en clase (23,8 %), relación con aplicaciones (4,8 %) y otros (4,8 %). El momento preferido fue por la tarde durante el estudio (66,7 %), confirmando el papel de alicIA como herramienta de apoyo al trabajo autónomo fuera del aula.

VI-B. Valoración de alicIA

La Tabla II presenta los estadísticos descriptivos de las preguntas en escala Likert (1–5). El ítem mejor valorado fue la fiabilidad de las respuestas ($\bar{x} = 4,06$, $\sigma = 0,94$, $N = 18$), seguido del enfoque socrático ($\bar{x} = 3,90$, $\sigma = 0,94$, $N = 21$) y la experiencia global ($\bar{x} = 3,86$, $\sigma = 1,01$, $N = 21$). El ítem con mayor dispersión fue la preferencia sobre ChatGPT




Figura 1. Usos principales de alicIA (respuesta múltiple, $N = 21$). Los porcentajes suman más de 100 % porque los estudiantes podían seleccionar varias opciones.




Figura 2. Distribución de respuestas Likert por ítem ($N = 18-21$). Las categorías 1-2 se representan a la izquierda (desacuerdo), 3 como neutral y 4-5 a la derecha (acuerdo).

genérico ($\sigma = 1,29$), reflejando opiniones divididas sobre la conveniencia de un enfoque socrático frente a uno directo. En la mayoría de ítems, más del 70 % de las respuestas se sitúan en 4-5 (acuerdo), con porcentajes mínimos en desacuerdo (1-2). La Figura 2 muestra la distribución completa de respuestas mediante un gráfico divergente.

VI-C. Comparativa con ChatGPT genérico

El 57,1 % ($N = 12$) de los encuestados declaró haber usado tanto alicIA como ChatGPT genérico, el 28,6 % ($N = 6$) usó principalmente herramientas genéricas y el 14,3 % ($N = 3$) usó exclusivamente alicIA (Figura 3). Este resultado indica que los estudiantes combinan activamente múltiples herramientas de IA, configurando una *ecología de herramientas* en la que el asistente especializado y el genérico desempeñan roles complementarios.

VI-D. Transferibilidad y comentarios cualitativos

El 76,2 % ($N = 16$) de los encuestados recomendaría una herramienta similar en todas las asignaturas, un 19,0 % ($N = 4$) indicó que dependería del curso y un 4,8 % ($N = 1$) la recomendaría específicamente en asignaturas matemáticas o técnicas (Figura 4). Ningún encuestado desaconsejó su uso.

Los comentarios cualitativos, analizados mediante codificación temática [16], revelan cinco patrones principales:

Tabla II
VALORACIÓN DE ALICIA (ESCALA LIKERT 1-5)

Ítem	N	$\bar{x}$	$\tilde{x}$	σ
Comprensión de conceptos	21	3,76	4,0	0,83
Enfoque socrático útil	21	3,90	4,0	0,94
Fiabilidad de respuestas	18	4,06	4,0	0,94
Preferencia vs. ChatGPT	21	3,43	4,0	1,29
Complemento a las clases	18	3,72	4,0	1,02
Experiencia global	21	3,86	4,0	1,01




Figura 3. Uso combinado de alicIA y herramientas de IA genéricas ($N = 21$).

(T1) Especialización y alineación con el curso. Varios estudiantes valoraron positivamente que alicIA utilice la notación y los contenidos exactos de la asignatura:

“Unlike other AIs, it is highly specialized in cryptography and very focused on the exact topics covered in our course.”

Otro destacó su utilidad para búsqueda rápida de contenidos teóricos:

“I find it very useful to search theory concepts very quickly instead of looking at every slide.”

(T2) Autodiagnóstico y reducción de la intimidación. alicIA fue percibida como herramienta de verificación del propio aprendizaje:

“It helped me a lot, specially to verify whether I deeply understood the required concepts or not.”

Un comentario especialmente revelador ilustra el impacto emocional:

“I don’t feel intimidated by the course with a tool like this [...] knowing you have a guide really motivates me.”

(T3) Tensión socrática: guía vs. respuesta directa. La frustración con el enfoque socrático fue la limitación más recurrente. Algunos estudiantes expresaron preferencia por respuestas completas en ciertos momentos:

“it is a bit frustrating when it does not give you directly the answer.”

Sin embargo, un estudiante con conocimientos previos matizó:

“having a tailored AI system for the course is a good help, and allowing students to rely on it but without having all of the answers is a great way to boost productivity while still learning.”

(T4) Limitaciones de la plataforma. Varios estudiantes señalaron que el límite de *prompts* de la versión gratuita de ChatGPT impedía un uso sostenido de alicIA:




Figura 4. Recomendación de uso de una herramienta similar en otros cursos (N = 21).

“after 5 prompts more or less it stops working [...] without a subscription it is impossible to use it.”

Esta es una limitación técnica relevante que afecta directamente a la equidad de acceso.

(T5) Riesgo de sustitución de la asistencia presencial.

Un comentario aislado pero revelador apunta a un efecto no previsto:

“it has also contributed to me skipping more classes [...] I was relieved because I knew I could do it with alicIA [...] I took longer to recover the lost classes because I knew that I could always ask alicIA.”

Aunque se trata de un único caso, este testimonio señala un riesgo emergente que merece atención en futuros despliegues: la posibilidad de que un asistente suficientemente eficaz pueda, paradójicamente, incentivar el absentismo en lugar de complementar la asistencia presencial.

VII. DISCUSIÓN

VII-A. Contribuciones y fortalezas

alicIA representa una de las primeras experiencias documentadas de un GPT personalizado socrático para criptografía en el contexto universitario español. Frente a CodeHelp [2] o CodeAid [3], que se centran en programación donde la verificación es automática (ejecución de código), y frente a tutores socráticos en física [9], donde las respuestas pueden contrastarse experimentalmente, alicIA aborda un dominio donde no se puede “ejecutar” una demostración de seguridad, haciendo los guardrails más necesarios y su diseño más exigente.

El diseño incorpora decisiones que van más allá del *prompt engineering*: la exigencia de articular el intento previo como prerequisite de la ayuda, la técnica de aprendizaje por analogía, y la regla de prioridad de los apuntes que establece un marco de confianza verificable frente a alucinaciones.

La tensión entre el enfoque socrático y el deseo de respuestas directas (T3), reflejada en los comentarios, es un hallazgo relevante que confirma observaciones similares tanto en programación [8] como en estudios experimentales en K-12 [10]. El hecho de que el 57,1 % de estudiantes combine alicIA con ChatGPT genérico puede interpretarse positivamente: alicIA para aprender y razonar, ChatGPT para verificar y consultar rápidamente. Esta complementariedad no prevista refuerza la idea de que el valor del asistente socrático no reside en ser

la *única* herramienta, sino en ocupar un nicho pedagógico diferenciado dentro de un ecosistema de IA [3].

El hallazgo T5 sobre el riesgo de sustitución de la asistencia presencial, aunque anecdótico, conecta con la literatura sobre sobredependencia cognitiva de la IA [4] y merece una reflexión cuidadosa. A diferencia de los riesgos documentados de copia de soluciones, este efecto surge precisamente porque el asistente es percibido como *útil* y *alineado*, generando una confianza que puede desplazar otros recursos docentes. En futuras iteraciones, esta recomendación de complementariedad podría concretarse de varias formas. Por ejemplo, alicIA podría incorporar una regla que, ante dudas sobre demostraciones largas o sobre la intuición detrás de un resultado, redirija al estudiantado a las tutorías presenciales o a seminarios de problemas. Las directrices de uso también podrían incluir un recordatorio periódico dentro del propio diálogo (cada k interacciones, por ejemplo), señalando que alicIA complementa pero no sustituye la asistencia a clase. A más largo plazo, si se dispusiera de logs de interacción, se podrían correlacionar patrones de uso intensivo con tasas de asistencia para detectar posibles problemas a tiempo.

Los resultados cuantitativos (valoraciones promedio superiores a 3,7/5 en todos los ítems, 76,2 % de recomendación para otros cursos, 0 % de rechazo) y los temas cualitativos T1 y T2 sugieren que el enfoque socrático es percibido como útil y alineado con los objetivos de aprendizaje, especialmente para estudiantes que buscan consolidar comprensión profunda y reducir la intimidación.

VII-B. Limitaciones

Este trabajo presenta varias limitaciones metodológicas que condicionan la generalización de los resultados.

Muestra y representatividad. Con $N = 21$ de más de 100 matriculados (tasa de respuesta ≈ 20 %), la muestra limita la representatividad estadística. El sesgo de autoselección puede favorecer usuarios más activos o con opiniones más marcadas. Estudios futuros deberían emplear estrategias de muestreo estratificado o incentivos para aumentar la tasa de respuesta.

Ausencia de grupo de control. No disponemos de medidas de rendimiento académico comparativas (con y sin alicIA) ni de datos longitudinales que permitan evaluar el impacto en el aprendizaje más allá de la percepción.

Ausencia de logs de interacción. La plataforma de GPTs personalizados no proporciona logs detallados de uso, lo que impide analizar patrones de interacción reales, tipos de preguntas formuladas y evolución del uso a lo largo del trimestre.

Comparativa cualitativa con ChatGPT. La comparación con ChatGPT genérico (Tabla I) es ilustrativa pero no cuantifica la frecuencia de alucinaciones ni errores en demostraciones complejas.

Equidad de acceso. La dependencia de una suscripción de pago para uso intensivo (T4) plantea cuestiones de equidad que no fueron abordadas en este despliegue inicial.

Además, a fecha del envío a JNIC (marzo de 2026) todavía no se ha completado el análisis del rendimiento académico asociado a esta cohorte; está previsto realizar durante el mes de marzo un estudio adicional comparando resultados de evaluación con cohortes previas, con el fin de complementar la evidencia de percepción con indicadores de rendimiento.

VII-C. Lecciones para la docencia en ciberseguridad

A partir de esta experiencia, destacamos cuatro lecciones prácticas para el diseño de asistentes basados en LLM en asignaturas de ciberseguridad:

(L1) Alineación fuerte con el plan docente. Incorporar los apuntes oficiales como base de conocimiento y explicitar una regla de prioridad (“si alicIA contradice los apuntes, prevalecen los apuntes”) ayuda a construir un marco de confianza verificable frente a alucinaciones y discrepancias terminológicas.

(L2) Guardrails socráticos explícitos, no solo buenos prompts. La combinación de límites claros (no dar soluciones completas), exigencia de intento previo y uso de analogías controladas resulta clave para desplazar el foco desde “obtener respuesta” hacia “razonar el proceso”, especialmente en dominios donde no se puede verificar el resultado ejecutando código.

(L3) Aceptación de la ecología de herramientas. El estudiantado combina de forma natural alicIA con LLMs genéricos: usa el asistente especializado para aprender con la notación del curso y recurre a modelos generales para contrastar o pedir explicaciones alternativas. En lugar de intentar prohibir este ecosistema, parece más fructífero diseñar herramientas que ocupen un nicho pedagógico claro dentro de él.

(L4) Necesidad de evidencia más allá de la percepción. Aunque las encuestas de satisfacción y los comentarios cualitativos son valiosos como primera evaluación, la siguiente etapa debe medir el impacto en el rendimiento académico y analizar patrones de interacción reales, siempre con consentimiento informado.

Estas lecciones son transferibles a otras asignaturas de criptografía y ciberseguridad que deseen integrar IA generativa de forma responsable, y proporcionan un punto de partida para diseñar asistentes específicos con un equilibrio explícito entre ayuda y exigencia cognitiva.

VII-D. Trabajo futuro

Identificamos varias líneas prioritarias:

Evaluación de impacto en rendimiento académico. Comparar cohortes con y sin alicIA mediante diseño cuasi-experimental, controlando variables confusoras (nota de acceso, experiencia previa en matemáticas). En particular, durante el mes de marzo de 2026 se llevará a cabo un análisis comparando resultados de evaluación de esta cohorte con cursos anteriores.

Análisis de logs de interacción. Implementar un sistema de registro con consentimiento para caracterizar tipos de preguntas, patrones de uso y correlación con rendimiento.

Mecanismos de verificación automática. Integrar SageMath para verificación de cálculos en aritmética modular y propiedades de grupos, ampliando el alcance del feedback automático.

Transferibilidad a otras asignaturas. Replicar el diseño en asignaturas relacionadas (Blockchain, Protocolos criptográficos, Seguridad de redes) para evaluar la generalización del enfoque.

Comparativa multi-modelo. Evaluar robustez del enfoque socrático con diferentes LLMs subyacentes (GPT-4o, Claude, Gemini).

Solución a limitaciones de acceso. Explorar alternativas de despliegue institucional (licencias campus, implementación local con modelos abiertos) para garantizar equidad.

VIII. CONCLUSIONES

Hemos presentado alicIA, un GPT personalizado socrático para la asignatura de Criptografía y Seguridad de la UPF, integrado formalmente en la metodología docente. El diseño se fundamenta en once reglas pedagógicas, agrupadas en bloques temáticos, que implementan principios socráticos (como no dar la respuesta final, exigir la articulación del intento previo y guiar mediante preguntas y analogías) adaptados al dominio de la criptografía.

Los resultados de la encuesta voluntaria en línea ($N = 21$, tasa de respuesta $\approx 20\%$) muestran una valoración positiva del enfoque socrático ($\bar{x} = 3,90/5$), alta percepción de fiabilidad ($\bar{x} = 4,06/5$), y una experiencia global favorable ($\bar{x} = 3,86/5$). El $76,2\%$ de los encuestados recomendaría una herramienta similar en todas sus asignaturas, y ninguno desaconsejó su uso.

El análisis temático cualitativo reveló cinco patrones principales: especialización y alineación con el curso (T1), utilidad para autodiagnóstico y reducción de la intimidación (T2), tensión productiva entre guía socrática y deseo de respuestas directas (T3), limitaciones técnicas de acceso (T4), y riesgo emergente de sustitución de la asistencia presencial (T5). El $57,1\%$ combinó activamente alicIA con ChatGPT genérico, evidenciando una ecología de herramientas donde el asistente especializado ocupa un nicho pedagógico diferenciado.

Este artículo se centra deliberadamente en la fase de diseño e implementación y en la percepción del estudiantado tras el primer despliegue de alicIA; la evaluación sistemática del impacto en resultados de aprendizaje se realizará a posteriori, una vez cerradas las actas del curso 2025–26. El caso de la criptografía resulta particularmente relevante para la comunidad de educación en ciberseguridad: la imposibilidad de verificar automáticamente las demostraciones, a diferencia de la programación, hace que los guardrails pedagógicos sean aún más necesarios que en otros dominios. En este sentido, alicIA ofrece un ejemplo concreto de cómo los LLM pueden integrarse en la docencia universitaria no como oráculo que resuelve ejercicios, sino como un compañero socrático que ayuda a estructurar el trabajo del estudiante.

Las lecciones extraídas (alineación con el plan docente, guardrails socráticos explícitos, aceptación de la ecología de herramientas y necesidad de evidencia más allá de la percepción) proporcionan un marco replicable para el diseño de asistentes docentes basados en IA en ciberseguridad y disciplinas relacionadas.

AGRADECIMIENTOS

Las autoras agradecen a todos los estudiantes que participaron voluntariamente en la encuesta.

Este trabajo cuenta con el apoyo de la Cátedra Artemisa, una iniciativa desarrollada en el marco de los fondos del Plan de Recuperación, Transformación y Resiliencia, financiado por la Unión Europea (Next Generation), el proyecto del Gobierno de España que traza la hoja de ruta para la modernización de la economía española, la recuperación del crecimiento económico y la creación de empleo, para una

reconstrucción económica sólida, inclusiva y resiliente tras la crisis de la COVID-19, y para responder a los desafíos de la próxima década.

REFERENCIAS

- [1] J. Katz and Y. Lindell, *Introduction to Modern Cryptography*, 3rd ed. Chapman & Hall/CRC, 2020.
- [2] M. Liffiton, B. E. Sheese, J. Savelka, and P. Denny, "CodeHelp: Using Large Language Models with Guardrails for Scalable Support in Programming Classes," in *Proc. 23rd Koli Calling Int. Conf. on Computing Education Research*. ACM, 2023, pp. 1–11, doi: 10.1145/3631802.3631830.
- [3] M. Kazemitabaar *et al.*, "CodeAid: Evaluating a Classroom Deployment of an LLM-based Programming Assistant that Balances Student and Educator Needs," in *Proc. CHI Conf. on Human Factors in Computing Systems (CHI '24)*. ACM, 2024, pp. 1–20, doi: 10.1145/3613904.3642773.
- [4] C. Zhai, S. Wibowo, and L. D. Li, "The effects of over-reliance on AI dialogue systems on students' cognitive abilities: A systematic review," *Smart Learning Environments*, vol. 11, art. 28, 2024, doi: 10.1186/s40561-024-00316-7.
- [5] R. Liu, C. Zenke, C. Liu, A. Holmes, P. Thornton, and D. J. Malan, "Teaching CS50 with AI: Leveraging Generative Artificial Intelligence in Computer Science Education," in *Proc. 55th ACM Technical Symposium on Computer Science Education (SIGCSE TS '24)*. ACM, 2024, doi: 10.1145/3626252.3630938.
- [6] Z. Liu *et al.*, "SocraticLM: Exploring Socratic Personalized Teaching with Large Language Models," in *Advances in Neural Information Processing Systems (NeurIPS 2024)*, 2024.
- [7] L. Favero, J. A. Pérez-Ortiz, T. Käser, and N. Oliver, "Enhancing Critical Thinking in Education by Means of a Socratic Chatbot," in *AI in Education and Educational Research (AIEER 2024)*, *Communications in Computer and Information Science (CCIS)*, vol. 2519. Springer, 2025, pp. 17–32, doi: 10.1007/978-3-031-93409-4_2.
- [8] R. Gupta, H. Goyal, D. Kumar, A. Mehra, S. Sharma, K. Mittal, and J. S. Challa, "Saksham AI: Advancing AI-Assisted Coding Education for Engineering Students in India Through Socratic Tutoring and Comprehensive Feedback," *arXiv preprint arXiv:2503.12479*, 2025, doi: 10.48550/arXiv.2503.12479.
- [9] E. Tufino and B. Gregorcic, "Creating a customisable Socratic AI physics tutor," *Physics Education*, vol. 60, no. 6, p. 065037, 2025.
- [10] A. Blasco and V. Charisi, "Exploring the Role of AI Chatbots in K-12 Education: A Comparative Study of Socratic and Non-Socratic Approaches," *SSRN*, 2024, SSRN abstract_id: 5040921.
- [11] H. Molina-Montalvo, J. C. Macías Villarreal, and G. Haces Atondo, "Impacto, percepciones y uso de ChatGPT en la formación de estudiantes de pedagogía y educación. Un estudio diagnóstico en diez universidades de México," *Revista Tecnología, Ciencia y Educación*, no. 31, pp. 59–89, 2025, doi: 10.51302/tce.2025.24301.
- [12] F. Vásquez Cardona, V. Carmona García, and D. Pérez Valencia, "ChatGPT in Higher Education: A Cross-Sectional Study of Student Usage, Ethical Perceptions, and Implications for Academic Integrity," *Revista de Bioética y Derecho*, no. 65, pp. 101–119, 2025, doi: 10.1344/rbd2025.65.49416.
- [13] M. Segarra Ciprés, R. Grangel Seguer, and Ó. Belmonte Fernández, "ChatGPT como herramienta de apoyo al aprendizaje en la educación superior: una experiencia docente," *Revista Tecnología, Ciencia y Educación*, no. 28, pp. 7–44, 2024, doi: 10.51302/tce.2024.19083.
- [14] H. N. Boone and D. A. Boone, "Analyzing Likert Data," *Journal of Extension*, vol. 50, no. 2, 2012.
- [15] G. Norman, "Likert scales, levels of measurement and the 'laws' of statistics," *Advances in Health Sciences Education*, vol. 15, no. 5, pp. 625–632, 2010, doi: 10.1007/s10459-010-9222-y.
- [16] V. Braun and V. Clarke, "Using thematic analysis in psychology," *Qualitative Research in Psychology*, vol. 3, no. 2, pp. 77–101, 2006, doi: 10.1191/1478088706qp0630a.

Premios RENIC a la mejor tesis doctoral y al
mejor trabajo fin de máster

Premio al mejor trabajo fin de máster

RENIC 2026 Mejor Trabajo de Fin de Máster

UNIVERSIDAD NACIONAL DE EDUCACIÓN A DISTANCIA

ESCUELA TÉCNICA SUPERIOR DE INGENIERÍA INFORMÁTICA

Máster Universitario en Investigación en Inteligencia Artificial



Trabajo Fin de Máster

**Evaluación Exhaustiva de Riesgos de Privacidad Basada en IA en Aplicaciones Móviles y
Redes Sociales**

Daniel Blanco Aza

Tutores

Antonio Robles Gómez, Rafael Pastor Vargas

MADRID, JUNIO 2025

Novedad del trabajo y aportación a la ciberseguridad

Contexto y problema

La superficie de ataque de la privacidad en *apps* móviles y redes sociales no se limita a un único artefacto: se reparte entre (i) lo que el código y sus bibliotecas de terceros hacen realmente (flujos de PII, telemetría, exfiltración, configuraciones), (ii) lo que el producto declara a través de políticas de privacidad y Términos de Servicio (ToS), y (iii) la obligación de alinear esas prácticas con marcos regulatorios (RGPD, DSA, CPRA) y principios de ingeniería de la privacidad. El estado del arte tiende a tratar estas piezas de forma fragmentada (p. ej., solo permisos, solo políticas, o solo análisis estático), lo que dificulta: cuantificar el riesgo de manera comparable, priorizar mitigaciones, y ofrecer trazabilidad suficiente para auditoría y cumplimiento.

Novedad del trabajo

La novedad del TFM reside en la consolidación, operacionalización y validación de un marco integrado (SafeMountain) que convierte el análisis de privacidad en un problema de *ciberseguridad medible y verificable*. En concreto, el trabajo aporta:

1. Integración *end-to-end* de evidencias técnicas y semánticas. SafeMountain unifica, en una arquitectura modular, *análisis estático y dinámico* del comportamiento (incluyendo flujos y fugas de PII, y tráfico de red) con *PLN* para interpretar políticas de privacidad/ToS. El resultado es una verificación cruzada (*código/permisos ↔ declaraciones*) que permite detectar incoherencias, omisiones y potenciales incumplimientos con base en evidencias de ejecución, no solo en texto o metadatos.
2. Un sistema de puntuación objetiva del riesgo, alineado con ingeniería de privacidad. El trabajo formaliza una metodología de *risk scoring* inspirada en NISTIR 8062, articulada en dimensiones operativas (previsibilidad, gestionabilidad y disociabilidad) que conectan decisiones técnicas con impactos en derechos y cumplimiento. Esta capa convierte hallazgos heterogéneos en una puntuación comparable entre aplicaciones, soportando priorización y seguimiento.
3. Visualización explicable y accionable mediante esquema de semáforo. La salida no se limita a un “score”: se traduce a un esquema visual (verde/amarillo/rojo) orientado a usuarios, desarrolladores y perfiles de cumplimiento. Esto reduce la brecha entre detección y acción correctiva, y habilita una comunicación de riesgo consistente en auditorías y procesos de *security governance*.
4. Automatización con IA para escalar la caracterización de políticas y cumplimiento. El trabajo incorpora un módulo de automatización (DeepMountain) que aplica modelos de PLN y aprendizaje profundo para tareas como alineamiento permiso–política, caracterización de cumplimiento

y soporte multilingüe. Esta automatización reduce el coste de evaluación a gran escala y habilita replicabilidad en nuevos conjuntos de aplicaciones.

5. Cobertura multilingüe y enfoque socio-técnico del riesgo. Se trabaja con un corpus que incluye documentos en inglés y español, y se explicita la necesidad de robustez en contextos multilingües. Además, el marco considera el impacto sobre colectivos vulnerables (p. ej., menores), incorporando una perspectiva de riesgo que es relevante tanto para la seguridad como para la protección de derechos.

Aportación a la ciberseguridad

Aunque la privacidad se formula a menudo como cumplimiento normativo, el TFM la aborda como ciberseguridad aplicada por tres razones: (i) la exposición de PII habilita vectores de ataque (ingeniería social, suplantación, doxxing, acoso), (ii) la presencia de bibliotecas de terceros y telemetría introduce riesgos de cadena de suministro, y (iii) la discrepancia entre lo declarado y lo ejecutado es un indicador de falta de control y de *accountability* del sistema.

En este marco, SafeMountain contribuye a la ciberseguridad mediante:

- Detección temprana de exposiciones de PII y posibles fugas: al inspeccionar fuentes y sumideros de datos y observar comportamientos en ejecución, el sistema apoya la identificación preventiva de escenarios de exfiltración o sobre-recolección.
- Reducción del riesgo por terceros: al perfilar bibliotecas integradas y contrastar su comportamiento con lo declarado, se mejora la visibilidad sobre dependencias y prácticas de tratamiento fuera del código propio.
- Estandarización de evidencias para auditoría: la metodología produce salidas estructuradas (hallazgos → dimensiones → puntuación → semáforo) que facilitan controles de seguridad, revisiones internas y comunicaciones con reguladores.
- Soporte a *privacy-by-design* y *security-by-design*: al alinear la evaluación con principios de ingeniería de privacidad y con obligaciones regulatorias, se promueve un ciclo de mejora continua que impacta directamente en la postura de seguridad de aplicaciones y servicios.

El documento acota cuidadosamente el alcance: SafeMountain no pretende sustituir auditorías legales ni pruebas manuales de *pentesting*, sino proveer una capa automatizada, objetiva y repetible para detectar incoherencias y riesgos priorizables. La contribución principal es metodológica y de sistema: integrar señales heterogéneas (código, permisos, políticas) bajo un contrato de evaluación de riesgo y un mecanismo de comunicación explicable, orientado a decisiones de ciberseguridad y cumplimiento.

En resumen, la novedad del TFM no es un algoritmo aislado, sino la construcción de un marco integrado y operativo que convierte el análisis de privacidad en una práctica de ciberseguridad: medible, trazable y accionable. SafeMountain aporta una visión holística (técnica + semántica + regulatoria), un *risk scoring* fundamentado en ingeniería de privacidad, y una presentación de resultados comprensible que habilita decisiones de mitigación por parte de usuarios, desarrolladores y organizaciones.

Resultados obtenidos

El TFM ha producido resultados verificables en tres ejes: (i) publicación científica en revista Q1, (ii) difusión y validación externa mediante ponencias/pósters en eventos de ciberseguridad e IA, y (iii) transferencia de conocimiento a la comunidad (sensibilización sobre riesgos de privacidad, con foco en bibliotecas de terceros y comportamiento real de *apps*).

1) Publicaciones (revistas)

- Cluster Computing – Revista JCR Q1 (publicado).
Blanco-Aza, D., Robles-Gómez, A., Pastor-Vargas, R. et al. *Comprehensive AI-driven privacy risk assessment in mobile apps and social networks*. Cluster Computing 28, 914 (2025). DOI: <https://doi.org/10.1007/s10586-025-05624-2>.

2) Congresos, conferencias y eventos (ponencias y pósters)

- ICSC 2024 (ponencia). *The Fourth Intelligent Cybersecurity Conference (ICSC2024)*.
Título: *Comprehensive AI-Driven Privacy Risk Assessment in Mobile Apps and Social Networks*.
Enlace: ICSC 2024
- Global AI Bootcamp – Ponferrada (ponencia).
Título: *Comprehensive AI-Driven Privacy Risk Assessment in Mobile Apps and Social Networks*.
Enlace: Global AI Bootcamp – Ponferrada
- JNIC 2025 (póster).
Título: *Análisis de Privacidad en Aplicaciones Móviles y Redes Sociales mediante Técnicas de IA*.
Enlace: JNIC 2025
- Jornadas de Talento en Ciberseguridad e IoT 2025 (ponencia).
Título: *Bibliotecas de terceros: riesgos de privacidad en apps*.
Enlace: Jornadas de Talento en Ciberseguridad e IoT 2025
- XIX Reunión Española sobre Criptología y Seguridad de la Información (póster).
Título: *AI-Driven Privacy Risk Analysis for Mobile Apps and Social Networks*.
Enlace: XIX Reunión Española sobre Criptología y Seguridad de la Información

3) Transferencia e impacto

- Transferencia a la práctica (ePalSafer): el marco de evaluación del riesgo de privacidad (*Safe-Mountain*) se ha trasladado a un artefacto operativo mediante el sitio web y aplicación ePalSafer, que permite consultar y explorar resultados de análisis para *apps* y servicios, facilitando su uso por perfiles técnicos y de ciberseguridad.
Enlace: ePalSafer
- Transferencia del código y reutilización: el código del proyecto se ha compartido públicamente para facilitar reproducibilidad, extensión y adopción por terceros en el repositorio.
Enlace: GitHub
- Concienciación y formación: las ponencias y pósters han servido para trasladar hallazgos prácticos sobre riesgos reales (p. ej., bibliotecas de terceros y telemetría) y criterios de evaluación reproducibles para priorización de mitigaciones.

Resumen

1) Contexto, motivación y problema

La adopción masiva de *apps* móviles y redes sociales ha intensificado el tratamiento (a menudo opaco) de información personal y metadatos sensibles, lo que incrementa la exposición a riesgos de ciberseguridad: suplantación, doxxing, ingeniería social, perfilado no deseado y filtraciones por terceros (bibliotecas integradas, telemetría y *trackers*). Aunque marcos como el RGPD han elevado las obligaciones de transparencia y control, en la práctica persisten tres brechas técnicas recurrentes: (i) discrepancia entre lo declarado en políticas de privacidad/ToS y el comportamiento real de la aplicación; (ii) falta de visibilidad y trazabilidad sobre bibliotecas de terceros (TPLs) y su rol en el tratamiento de datos; y (iii) ausencia de una metodología objetiva y comparable para medir el riesgo y priorizar mitigaciones.

Este TFM aborda el análisis del riesgo de privacidad como un problema de ciberseguridad medible y verificable, proponiendo un marco integrado que combina evidencias técnicas (código, permisos, bibliotecas, tráfico) con evidencias semánticas (texto legal y declarativo), y las traduce a una puntuación de riesgo y un esquema explicable de comunicación.

2) Objetivos

El objetivo general es diseñar, implementar y validar un marco automatizado para identificar, medir y representar riesgos de privacidad en *apps* móviles y redes sociales, alineado con ingeniería de privacidad y regulación. En particular:

- Marco integrado de análisis: unificar análisis estático y dinámico del comportamiento (incluyendo identificación de flujos/uso de PII y tráfico de red) con PLN para interpretar políticas de privacidad y ToS.
- Cobertura de TPLs: recolectar y perfilar bibliotecas de terceros y su integración real en aplicaciones, detectando dependencias y riesgos no declarados.
- Evaluación objetiva del riesgo: definir un sistema de puntuación por dimensiones alineadas con NISTIR 8062 (previsibilidad, gestionabilidad, disociabilidad) y una matriz probabilidad–impacto, con salida tipo semáforo.
- Visualización y accionabilidad: producir resultados comprensibles para distintos perfiles (técnico, cumplimiento, usuario), manteniendo trazabilidad para auditoría.

3) Metodología de investigación y diseño

El trabajo sigue una metodología por fases:

1. Revisión del estado del arte (PRISMA-like): identificación de enfoques de evaluación del riesgo de privacidad (permisos vs. texto, análisis de tráfico, consistencia política–código, riesgos por

terceros) y de sus limitaciones (cobertura parcial, dependencia del idioma, falta de estandarización del riesgo).

2. Generación de dataset/corpus: recopilación automatizada de aplicaciones y metadatos, junto con políticas de privacidad y ToS en un corpus multilingüe (inglés y español), con anotaciones manuales para disponer de referencias de validación.
3. Diseño e implementación del sistema: desarrollo modular del marco y definición del contrato de datos (entidades, evidencias, campos, trazabilidad) y del modelo de riesgo.
4. Evaluación experimental: ejecución de pipelines de análisis estático/dinámico, validación parcial manual (muestra estratificada) y análisis comparativo de hallazgos.
5. Despliegue y validación futura: empaquetado y exposición del resultado mediante un artefacto consultable para facilitar su uso por terceros.

4) Arquitectura propuesta: SafeMountain y DeepMountain

La contribución técnica principal es SafeMountain, un marco modular que integra herramientas y modelos para cubrir el ciclo completo de evaluación del riesgo:

- AppCollector (recolección): descarga y organización de APKs y metadatos (identificadores, versión, categoría, etc.). En la experimentación se parte de las 200 aplicaciones más descargadas de la categoría de redes sociales en Google Play, con enriquecimiento de información sobre dependencias (TPLs).
- Análisis estático: identificación de permisos, uso de APIs sensibles, posibles rutas de exposición y señales de sobre-recolección mediante herramientas como Privado Scan y MobSF.
- Análisis dinámico: inspección del comportamiento en ejecución (incluido tráfico de red) con MobSF, para aportar evidencia empírica de comunicaciones y flujos activos.
- Análisis de bibliotecas de terceros (LIBLOOM) y verificación (ATPChecker): detección de TPLs embebidas (robusta ante ofuscación mediante perfiles y firmas difusas) y contraste de prácticas reales frente a lo declarado en políticas/ToS.
- PLN y automatización (DeepMountain): entrenamiento y ejecución automatizada de modelos (transformers) para tareas de caracterización semántica de políticas/ToS, alineamiento permiso-política y soporte multilingüe.

El diseño modular facilita extensiones (nuevas categorías, nuevas fuentes, iOS/HarmonyOS) y mitiga el acoplamiento a una herramienta concreta mediante *pipelines* intercambiables y artefactos trazables.

5) Modelo de riesgo: de evidencias a puntuación y semáforo

Para convertir hallazgos heterogéneos en una medida comparable, el sistema aplica una evaluación estructurada basada en:

- Dimensiones NISTIR 8062: *previsibilidad* (grado de transparencia/anticipabilidad del tratamiento), *gestionabilidad* (capacidad de control del usuario y del sistema) y *disociabilidad* (posibilidad de desvincular datos de la identidad o minimizar correlaciones).

- Matriz probabilidad–impacto: criterios alineados con guías regulatorias (incl. AEPD) para estimar probabilidad e impacto (muy limitado → muy significativo) y derivar un nivel de riesgo (bajo/medio/alto/muy alto).
- Presentación explicable: traducción de la puntuación a un semáforo (verde/amarillo/rojo), manteniendo la trazabilidad desde el indicador visual a la evidencia (permisos, tráfico, TPLs y fragmentos relevantes de políticas).

Para evitar sobre-interpretaciones, el sistema presenta los resultados como riesgos potenciales y complementa las métricas clásicas de clasificación (precisión, *recall*, F1, ROC-AUC) con indicadores de dominio (p. ej., porcentaje de permisos no documentados, tasa de desajuste política–código, cobertura de artículos RGPD), reforzando la interpretabilidad operativa.

6) Escenarios experimentales y resultados principales

La evaluación se realiza sobre un conjunto de aplicaciones de alto impacto (top-200 en redes sociales) y sus dependencias, ejecutando pipelines de recolección, análisis estático/dinámico, detección de TPLs y análisis semántico de políticas. La experimentación destaca:

- Viabilidad de un pipeline end-to-end: desde la descarga y organización de APKs y metadatos, hasta la agregación de evidencias técnicas y semánticas y su conversión a puntuaciones comparables.
- Identificación de riesgos por discrepancia: el contraste entre permisos/comportamiento observado y declaraciones textuales permite detectar incoherencias y omisiones relevantes para auditoría y cumplimiento.
- Peso operativo de terceros: el perfilado de bibliotecas de terceros aporta visibilidad sobre dependencias y prácticas no evidentes a nivel de la aplicación, alineando el análisis con riesgos de cadena de suministro.
- Robustez y control de calidad: se incorpora validación manual bilingüe de una muestra estratificada para acotar errores de interpretación del PLN y ajustar el proceso de mejora iterativa.

Asimismo, se documentan amenazas a la validez (sesgos por muestreo, cobertura de versiones en el espejo local de bibliotecas, deriva de herramientas y no determinismo del análisis dinámico) y sus mitigaciones (actualización periódica, contenerización, fijación de semillas y repetición de ejecuciones).

7) Implementación, disponibilidad y transferencia

El marco se entrega como un artefacto reproducible y transferible:

- Código y reproducibilidad: el código del proyecto se ha compartido como repositorio de código abierto, con documentación y ejemplos para facilitar su replicación y extensión.
- Datos y corpus: el corpus multilingüe (políticas/ToS y metadatos) se mantiene como recurso para entrenamiento y evaluación de los módulos de PLN y aprendizaje profundo.
- Despliegue operativo (ePalSafer): los resultados se trasladan a la práctica mediante un sitio web y aplicación que permite consultar y explorar análisis de riesgo, facilitando su uso por perfiles técnicos, de ciberseguridad y de cumplimiento.

8) Conclusiones y líneas futuras

El TFM demuestra que es posible transformar un conjunto disperso de señales (permisos, código, bibliotecas, tráfico, textos legales) en un proceso automatizado y trazable de evaluación del riesgo de privacidad, con valor directo para ciberseguridad aplicada: priorización de mitigaciones, auditoría y apoyo a *privacy-by-design/security-by-design*. Como extensiones naturales se proponen: (i) ampliar la cobertura a nuevas categorías (finanzas, salud) y muestreo aleatorio para robustez; (ii) extender el pipeline a iOS/HarmonyOS mediante adaptadores modulares; (iii) enriquecer la detección de PII y las heurísticas del semáforo con retroalimentación de reguladores/industria; y (iv) fortalecer la estabilidad experimental frente a deriva de herramientas con suites de regresión y validadores automáticos.

Premio a la mejor tesis doctoral

Summary Document for the Best PhD Thesis in Cybersecurity Award

Luis Ibáñez Lissen

1 de febrero de 2026

1. Novelty and Contribution to Cybersecurity

This doctoral thesis addresses one of the most critical challenges of the current digital decade: the convergence of Artificial Intelligence (AI) and Cybersecurity. As AI models—particularly Large Language Models (LLMs)—become integrated into critical infrastructure, the boundary between *AI as a tool* and *AI as a threat surface* has blurred.

Novelty and Approach The primary novelty of this research lies in its **holistic approach to Trusted AI**. Unlike traditional research that treats models as “black boxes,” this thesis proposes novel **“white-box” internal auditing techniques** and investigates the cognitive integrity of AI agents and LLMs.

While in the thesis the goals are in different orders, the contributions advance the state of the art in three interconnected pillars:

Pillar 1: Efficient Auditing of LLM Privacy and Security.

Focusing on internal state analysis to detect vulnerabilities without retraining.

Pillar 2: AI Safety and Deceptive Alignment.

Addressing the risks of models that feign obedience while harboring hidden reasoning.

Pillar 3: AI-driven Defense.

Leveraging AI to combat disinformation and ensure unauthorized access via continuous authentication.

1.1. Efficient Auditing via Internal States (Linear Probing)

A major bottleneck in current AI security research is the computational cost of auditing massive models. Traditional attacks or defenses often require retraining models or performing expensive gradient-based optimization.

Novelty: This thesis introduces a paradigm shift by leveraging Linear Probing techniques to audit the internal states of LLMs without the need for retraining or heavy computation. This represents a novel application of interpretability tools for cybersecurity purposes.

Key Contributions:

- **LUMIA (Linear Probing for Unimodal and MultiModal Membership Inference Attacks):** The thesis presents the first comprehensive framework utilizing linear probes to execute Membership Inference Attacks (MIA). By analyzing the internal activations of the model, we demonstrated that it is possible to infer whether a specific data point was used during training with high accuracy, yet with significantly lower computational overhead than existing state-of-the-art methods. This contributes a crucial tool for auditing GDPR compliance and data leakage in foundational models.

- **LPASS (Linear Probing as Stepping Stones):** We extended this methodology to compressed and quantized models. As LLMs are increasingly deployed on edge devices via compression, understanding if this compression masks or exposes vulnerabilities is vital. This work provides the first systematic study showing that linear probes can effectively detect vulnerabilities even in compressed latent spaces, serving as a stepping stone for more complex attacks or defenses.

1.2. AI Safety: Faithfulness, Steganography, and Deceptive Alignment

As AI systems evolve from chatbots into autonomous agents, the risk shifts from bugs to misalignment—models that feign obedience while harboring hidden goals or reasoning. This thesis contributes to the nascent field of AI Safety by exploring the limits of monitoring and supervision.

Novelty: The research challenges the assumption that Chain-of-Thought (CoT) reasoning is transparent. We provide empirical evidence that models can be trained to be deceptive even under strict process supervision.

Key Contributions:

- **Steganographic Chain-of-Thought:** In collaboration with researchers from the University of Cambridge and Google DeepMind, this thesis demonstrates—for the first time—that LLMs can learn to encode hidden information (steganography) within perfectly legible Chain-of-Thought reasoning. This finding (published at NeurIPS) is critical for the future of AI monitoring, as it proves that inspecting an AI’s thoughts is not a foolproof guarantee of its faithfulness.
- **Cross-Contamination in Multimodal Models:** We characterized how contamination (data leakage between training and testing sets) affects Multimodal Large Language Models (MLLMs). By rigorously analyzing how visual and textual modalities interact, this work highlights how benchmark contamination can create a false sense of security regarding a model’s capabilities and robustness.
- **Faithfulness in Multi-Agent Settings:** The thesis further explores how the interaction between multiple AI agents affects their faithfulness to the provided context. We proposed novel metrics to quantify hallucination and faithfulness when LLMs operate in collaborative environments, a scenario increasingly common in automated cyber-defense operations.

1.3. Societal Defense: Disinformation and Authentication

Beyond the theoretical security of models, this thesis applies advanced machine learning to solve pressing societal cybersecurity issues: the proliferation of disinformation and the need for robust user authentication.

Novelty: The work moves beyond generic detection to specific, context-aware solutions, focusing on the distinct linguistic characteristics of the Spanish landscape and the transferability of attacks.

Key Contributions:

- **Predictive Modeling of Disinformation (The Spanish Case):** This research provides one of the first in-depth feasibility studies on predicting the volume and spread of fake news specifically within the Spanish digital ecosystem. By analyzing temporal patterns and linguistic features, we developed models capable of forecasting disinformation spikes, enabling preemptive rather than reactive countermeasures.
- **Transfer Learning for Fake Reviews:** We demonstrated the economic feasibility of generating high-quality fake reviews using Transfer Learning. This work serves as a warning

to e-commerce platforms, showing that sophisticated, context-aware spam can be generated with minimal resources, necessitating more advanced detection filters.

- **Continuous Authentication via Matrix Profiles:** In the domain of identity management, the thesis introduces a novel continuous authentication mechanism utilizing Matrix Profiles. This time-series analysis technique allows for the detection of anomalies in user behavior with high precision and low latency, offering a robust alternative to static passwords or periodic biometric checks.

2. Results of this thesis

The following articles have been accepted as part of the research, covering A*, A, and B conferences as well as Q1 and Q2 journals. These works include collaborations with Inria, the University of Cambridge, Google DeepMind, and Imperial College London and other well recognized institutions.

- Ibáñez-Lissen, L., Fuentes García-Romero de Tejada, J. M. D., González-Manzano, L., & García-Alfaro, J. (2023). *Characterizing Cross-Contamination on Multitask Multimodal Large Language Models*. Information Systems Frontiers. [\[System Frontiers\]](#)
- Ibáñez-Lissen, L., De Fuentes, J. M., González-Manzano, L., & Anciaux, N. *Understanding LLM Faithfulness in Multi-Agent Settings Leveraging Chain-of-Thought Diversity* (Under review).
- Ibáñez-Lissen, L., González-Manzano, L., de Fuentes, J. M., & Anciaux, N. (2025). *LPASS: Linear Probes as Stepping Stones for vulnerability detection using compressed LLMs*. Journal of Information Security and Applications, 93, 104125. [\[DOI: 10.1016/j.jisa.2025.104125\]](#)
- Ibáñez-Lissen, L., González-Manzano, L., de Fuentes, J. M., Anciaux, N., & García-Alfaro, J. (2024). *LUMIA: Linear Probing for Unimodal and MultiModal Membership Inference Attacks Leveraging Internal LLM States*. In Computer Security – ESORICS 2025: 30th European Symposium on Research in Computer Security, Toulouse, France. Springer-Verlag. [\[ESORICS\]](#)
- Ibáñez-Lissen, L., Skaf, J., McCarthy, R., Watts, C., Georgiev, V., Whittingham, H., ... & Radmard, P. (2025). *Large language models can learn and generalize steganographic chain-of-thought under process supervision*. NEURIPS 2025. [\[NEURIPS\]](#)
- Ibáñez-Lissen, L., González-Manzano, L., de Fuentes, J. M., & Goyanes, M. (2023). *On the feasibility of predicting volumes of fake news—the Spanish case*. IEEE Transactions on Computational Social Systems. [\[DOI: 10.1109/TCSS.2023.3297093\]](#)
- Ibáñez-Lissen, L., González-Manzano, L., de Fuentes, J. M., & Goyanes, M. (2025). *Use of transfer learning for affordable in-context fake review generation*. IEEE Transactions on Big Data. [\[DOI: 10.1109/TBDATA.2025.3536927\]](#)
- Ibáñez-Lissen, L., De Fuentes, J. M., González-Manzano, L., & Anciaux, N. (2024). *Continuous Authentication Leveraging Matrix Profile*. In Proceedings of the 19th International Conference on Availability, Reliability and Security (ARES '24). ACM. [\[ARES\]](#)
- Buitrago-Perez, M., de Fuentes, J. M., Tejerina, O., Gonzalez-Manzano, L., Anciaux, N., & Ibáñez-Lissen, L. (2025, June). *XAI for safe AI: technical-legal misconceptions and misalignments*. In JNIC 2025 - Jornadas Nacionales de Investigación en Ciberseguridad.

- Ibáñez-Lissen, L., González-Manzano, L., de Fuentes, J. M., & Goyanes Martínez, M. (2024). *A Summary of on the feasibility of predicting fakenews appearance: the Spanish case*. In IX Jornadas Nacionales de Investigación en Ciberseguridad (JNIC 2024), pp. 446-447. ISBN 978-84-09-62140-8.

The following table serves as a summary of published content:

Tabla 1: Summary of Scientific Production

Type	Ranking / Quality	Accepted Papers
Journal	Q1	3 (+1 Under review)
Journal	Q2	1
Conference	Core A*	1
Conference	Core A	1
Conference	Core B	1
Other	JNIC paper/posters	2

Academic Recognitions and Grants

During the course of my PhD, I have been honored to receive the following recognitions:

- **Vulcanus in Japan Program (2023):** A competitive internship program fostering industrial/academic collaboration and cultural exchange between Europe and Japan, which provided valuable research experience in an international setting.
- **Cambridge University AI Safety Hub (2025):** A grant to participate and conduct joint investigation with Cambridge University.
- **SPAR AI Safety Hub (2025):** A grant to participate and conduct joint investigation with FAR AI.
- **French Embassy Research Grant (2025):** A grant awarded to support doctoral research mobility to France, enabling collaboration with French research institutions and contributing to the advancement of my doctoral work.

3. Summary

Since the seminal work of McCulloch and Pitts in 1943, who proposed the first mathematical model of an artificial neuron [12], AI research has advanced toward increasingly generalizable models. A major early milestone was Rosenblatt’s perceptron in 1958 [18], the first trainable neural network. While progress slowed due to the limitations of single-layer architectures, the introduction of backpropagation by Rumelhart, Hinton, and Williams in the 1980s [19] enabled scalable training of multi-layer networks, laying the foundation for modern deep learning. Recurrent neural networks (RNNs) became prominent in the 1990s and early 2000s but struggled with vanishing and exploding gradients, limiting their ability to capture long-term dependencies. These inefficiencies motivated the development of attention mechanisms [1] and ultimately the Transformer architecture [21], which has since displaced RNNs in most large-scale natural language tasks.

Transformers enabled the emergence of Large Language Models (LLMs), including BERT [5] and the GPT series [2, 16, 17], which leverage pre-training on massive datasets followed by fine-tuning or generative pre-training. Scaling laws [11] revealed predictable performance improvements with model size, leading to emergent capabilities such as arithmetic reasoning, translation, commonsense inference, and code generation [23]. Instruction tuning [22] and reinforcement learning from human feedback (RLHF) [14] further improved model alignment with human intent, but simultaneously expanded attack surfaces through prompt-based vulnerabilities and adversarial conditioning.

As models grow in scale and complexity, their security and controllability degrade. Empirical studies suggest that larger models may hallucinate more, exhibit reasoning unfaithfulness, and amplify adversarial vulnerabilities [4, 13, 25]. These concerns have accelerated interest in AI security and trustworthiness as central research priorities. Initiatives such as the OWASP GenAI Security Project¹, the NIST AI Risk Management Framework², ENISA’s multilayer framework, and ISO/IEC 23894:2023 provide structured methodologies for managing risks. In parallel, legislative efforts such as the EU AI Act³ aim to establish regulatory requirements for robustness, transparency, and monitoring. The economic implications are equally significant: PwC projects AI could contribute up to 14% of global GDP by 2030, approximately \$15.7 trillion⁴, while McKinsey estimates generative AI may generate \$2.6–\$4.4 trillion annually⁵. These projections underscore the urgency of ensuring security and trustworthiness, especially given the exponential growth of computational power and frontier-scale training trends [15].

This Thesis situates itself within the broad and multifaceted study of AI security, addressing technical, economic, and regulatory challenges necessary for building safe, reliable, and trustworthy AI systems. It is structured around three main goals:

- G1: Characterizing input-based threats to AI.** Investigates poisoning attacks and reasoning unfaithfulness.
- G2: Building trusted AI through observation and intervention.** Leverages latent representations and hidden states for interpretability and robustness.
- G3: Cybersecurity applications requiring trusted AI.** Explores real-world scenarios such as misinformation and fake reviews.

¹<https://genai.owasp.org/introduction-genai-security-project/>

²<https://www.nist.gov/itl/ai-risk-management-framework>

³<https://artificialintelligenceact.eu>

⁴<https://www.pwc.com/gx/en/issues/analytics/assets/pwc-ai-analysis-sizing-the-prize-report.pdf>

⁵<https://www.mckinsey.com/business-functions/mckinsey-digital/our-insights/the-economic-potential-of-generative-ai-the-next-productivity-frontier>

Together, these goals span the technical, methodological, and applied dimensions of AI security, forming a foundation for building trusted AI.

Goal 1: Input-based Threats. The first goal focuses on adversarial manipulation of inputs to induce malicious or unfaithful behavior in AI systems. We conducted a systematic study of poisoning attacks on Multimodal Multitask Large Language Models (MMLLMs) [6], including visual backdoors, label flipping, and textual triggers. These models, which integrate either modality-specific encoders or shared joint representations, present an enlarged attack surface exploitable by adversaries. While backdoor attacks on unimodal models are well-studied [24], the transferability of such attacks across modalities and tasks remains largely unexplored. Our contribution was to introduce backdoor triggers via poisoning techniques [3], applied to images and texts from one task, and evaluate whether they could later be activated from unrelated tasks or modalities. For example, an image-based trigger could be activated by partially embedding it in frames of a video used in a captioning task. Our results demonstrate that such cross-modal transferability is feasible even with low poison budgets, revealing that vulnerabilities propagate across tasks and modalities, which complicates defensive measures. Building on this idea of transferability, we also investigated inter-model influence in multi-agent scenarios where Chains-of-Thought (CoTs) are shared for verification or task decomposition. By generating diverse CoTs and distributing them across multiple model families, languages, and sizes, we observed systematic biases induced by exposure to external reasoning traces. These results reveal that reasoning artifacts are transferable between models, raising concerns about faithfulness in collaborative pipelines.

Goal 2: Trusted AI via Observation. The second goal shifts from input manipulation to internal mechanisms, focusing on how model activations and hidden states can be observed, leveraged, and intervened upon to build trust. In *LPASS* [9], we showed that linear probes can predict a model’s performance on code vulnerability detection tasks. Probing activations across layers allowed us to identify optimal truncation points, enabling compression of up to 80% of a model’s parameters while preserving near-original accuracy. This not only reduces training time and computational cost but also contributes to greener and more accessible AI. Building on this, we developed *LUMIA* [10], a framework for membership inference attacks (MIA) leveraging internal states of LLMs. By training linear probes on hidden representations, we improved the state-of-the-art performance in both unimodal and multimodal MIA, achieving AUC scores above 0.6. These results highlight that model activations leak sensitive information, raising privacy concerns even when outputs appear benign. Finally, we studied the behavior of reasoning under supervision in *Large Language Models Can Learn and Generalize Steganographic Chain-of-Thought Under Process Supervision* [20]. Here we found that LLMs, when guided by process supervision, can internalize reasoning steps in ways that are not externally observable, effectively encoding steganographic CoTs. These covert reasoning traces generalize across tasks and models, maintaining output performance while concealing intermediate logic. This challenges the assumption that monitoring visible CoTs suffices for interpretability, underscoring the need for hidden-state analysis as a complementary observation strategy.

Goal 3: Applications in Cybersecurity. The third goal grounds these insights in real-world cybersecurity applications where trust in AI is both essential and fragile. In *On the Feasibility of Predicting Volumes of Fake News—The Spanish Case* [7], we partnered with the fact-checking organization Maldita.es to assess whether AI models can forecast misinformation surges. Using a dataset of over 298,000 real and 8,900 fake news articles from 2019–2022, we tested statistical baselines (ARIMA) and advanced recurrent models (LSTM, encoder–decoder, attention). LSTM with attention achieved the best results, reducing aggregated prediction error to 10.3% and daily prediction error to 28.7%. Crucially, the method relies solely on real news signals (via GDELT), providing a practical and proactive tool for journalists to anticipate misinformation

waves. Extending this line of work, in *Use of Transfer Learning for Affordable In-Context Fake Review Generation* [8], we investigated e-commerce manipulation through fake reviews. Fine-tuning T5 and BART on Yelp and Amazon datasets, we showed that attackers can generate context-specific fake reviews with minimal resources. Our experiments reveal that the linguistic quality of generated reviews is indistinguishable from real ones, human detection is ineffective (performance near random), and automatic detection with RoBERTa classifiers achieves only limited success, particularly against T5-based reviews. Moreover, as little as one hour of training and 8,000 genuine reviews sufficed to produce credible fakes, drastically lowering the entry barrier for malicious actors. Considering that fake reviews already impose an estimated \$152 billion annual cost on global markets, these findings highlight how advances in generative models can directly undermine trust in digital economies.

Together, these contributions illustrate a holistic framework for AI security. We characterized input-driven threats across modalities and collaborative settings, developed methods for probing and intervening on hidden states to build trustworthy models, and applied these insights to societal challenges of misinformation and market manipulation. This synThesis demonstrates that AI security must extend from adversarial robustness to interpretability to socio-economic impact. By bridging these dimensions, this Thesis provides both technical contributions and applied insights toward the design of safe, reliable, and trusted AI systems.

4. Thesis link

Here is the link to the thesis [\[Thesis Link\]](#)

Referencias

- [1] Dzmitry Bahdanau, Kyunghyun Cho, and Yoshua Bengio. Neural machine translation by jointly learning to align and translate. *arXiv preprint arXiv:1409.0473*, 2014.
- [2] Tom Brown, Benjamin Mann, Nick Ryder, Melanie Subbiah, Jared D Kaplan, Prafulla Dhariwal, Arvind Neelakantan, Pranav Shyam, Girish Sastry, Amanda Askell, et al. Language models are few-shot learners. *Advances in neural information processing systems*, 33:1877–1901, 2020.
- [3] Nicholas Carlini, Matthew Jagielski, Christopher A Choquette-Choo, Daniel Paleka, Will Pearce, Hyrum Anderson, Andreas Terzis, Kurt Thomas, and Florian Tramèr. Poisoning web-scale training datasets is practical. In *2024 IEEE Symposium on Security and Privacy (SP)*, pages 407–425. IEEE, 2024.
- [4] Yanda Chen, Joe Benton, Ansh Radhakrishnan, Jonathan Uesato, Carson Denison, John Schulman, Arushi Somani, Peter Hase, Misha Wagner, Fabien Roger, et al. Reasoning models don’t always say what they think. *arXiv preprint arXiv:2505.05410*, 2025.
- [5] Jacob Devlin, Ming-Wei Chang, Kenton Lee, and Kristina Toutanova. Bert: Pre-training of deep bidirectional transformers for language understanding. *arXiv preprint arXiv:1810.04805*, 2018.
- [6] Luis Ibáñez Lissen, José María de Fuentes García-Romero de Tejada, Lorena González Manzano, and Joaquín García Alfaro. Characterizing poisoning attacks on generalistic multimodal ai models. 2023.
- [7] Luis Ibañez-Lissen, Lorena González-Manzano, José M de Fuentes, and Manuel Goyanes. On the feasibility of predicting volumes of fake news—the spanish case. *IEEE Transactions on Computational Social Systems*, 2023.
- [8] Luis Ibañez-Lissen, Lorena González-Manzano, José M de Fuentes, and Manuel Goyanes. Use of transfer learning for affordable in-context fake review generation. *IEEE Transactions on Big Data*, 2025.
- [9] Luis Ibanez-Lissen, Lorena Gonzalez-Manzano, Jose Maria de Fuentes, and Nicolas Anciaux. Lpass: Linear probes as stepping stones for vulnerability detection using compressed llms. *Journal of Information Security and Applications*, 93:104125, 2025.
- [10] Luis Ibanez-Lissen, Lorena Gonzalez-Manzano, Jose Maria de Fuentes, Nicolas Anciaux, and Joaquin Garcia-Alfaro. Lumia: Linear probing for unimodal and multimodal membership inference attacks leveraging internal llm states. *arXiv preprint arXiv:2411.19876*, 2024.
- [11] Jared Kaplan, Sam McCandlish, Tom Henighan, Tom B Brown, Benjamin Chess, Rewon Child, Scott Gray, Alec Radford, Jeffrey Wu, and Dario Amodei. Scaling laws for neural language models. *arXiv preprint arXiv:2001.08361*, 2020.
- [12] Warren S McCulloch and Walter Pitts. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4):115–133, 1943.
- [13] Alexander Meinke, Bronson Schoen, Jérémy Scheurer, Mikita Balesni, Rusheb Shah, and Marius Hobbhahn. Frontier models are capable of in-context scheming. *arXiv preprint arXiv:2412.04984*, 2024.
- [14] Long Ouyang, Jeffrey Wu, Xu Jiang, Diogo Almeida, Carroll Wainwright, Pamela Mishkin, Chong Zhang, Sandhini Agarwal, Katarina Slama, Alex Ray, et al. Training language models to follow instructions with human feedback. *Advances in neural information processing systems*, 35:27730–27744, 2022.

- [15] Konstantin F Pilz, James Sanders, Robi Rahman, and Lennart Heim. Trends in ai supercomputers. *arXiv preprint arXiv:2504.16026*, 2025.
- [16] Alec Radford, Karthik Narasimhan, Tim Salimans, and Ilya Sutskever. Improving language understanding by generative pre-training. 2018.
- [17] Alec Radford, Jeffrey Wu, Rewon Child, David Luan, Dario Amodei, Ilya Sutskever, et al. Language models are unsupervised multitask learners. *OpenAI blog*, 1(8):9, 2019.
- [18] Frank Rosenblatt. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6):386, 1958.
- [19] David E Rumelhart, Geoffrey E Hinton, and Ronald J Williams. Learning internal representations by error propagation. Technical report, 1985.
- [20] Joey Skaf, Luis Ibanez-Lissen, Robert McCarthy, Connor Watts, Vasil Georgiv, Hannes Whittingham, Lorena Gonzalez-Manzano, David Lindner, Cameron Tice, Edward James Young, et al. Large language models can learn and generalize steganographic chain-of-thought under process supervision. *arXiv preprint arXiv:2506.01926*, 2025.
- [21] A Vaswani. Attention is all you need. *Advances in Neural Information Processing Systems*, 2017.
- [22] Jason Wei, Maarten Bosma, Vincent Y Zhao, et al. Finetuned language models are zero-shot learners. *arXiv preprint arXiv:2109.01652*, 2021.
- [23] Jason Wei, Yi Tay, Rishi Bommasani, Colin Raffel, Barret Zoph, Sebastian Borgeaud, Dani Yogatama, Maarten Bosma, Denny Zhou, Donald Metzler, et al. Emergent abilities of large language models. *arXiv preprint arXiv:2206.07682*, 2022.
- [24] Pinlong Zhao, Weiyao Zhu, Pengfei Jiao, Di Gao, and Ou Wu. Data poisoning in deep learning: A survey. *arXiv preprint arXiv:2503.22759*, 2025.
- [25] Lexin Zhou, Wout Schellaert, Fernando Martínez-Plumed, Yael Moros-Daval, Cèsar Ferri, and José Hernández-Orallo. Larger and more instructable language models become less reliable. *Nature*, 634(8032):61–68, 2024.

Índice de Autores

- Agirre, Irune, 154
Agraz, Fernando, 368
Agudo, Isaac, 353
Aguiló Plana, Jan, 276
Aguirre-Ortuzar, Aitor, 274
Al Mahmud, Tamim, 95
Alarcón, Antonio, 31
Alegre, Enrique, 13
Alins, Juanjo, 31
Anciaux, Nicolas, 314
Anglés-Tafalla, Carles, 42, 170
Armendariz, Igor, 438
Arrasate-Mondragón, E-, 400
Arrieta, Aitor, 154
Arrizabalaga, Saioa, 158, 240
Author(s), Anonymous, 408
Avila, Mar, 70
- Bagheri-Gisour Marandyn, Farid, 220, 360
Batina, Lejla, 438
Baños Ramos, Andrea, 360
Bellés-Muñoz, Marta, 283
Beltrán-López, Pedro, 48, 61
Bermúdez, Lluís, 446
Blanco Aza, Daniel, 503
Blanco Chacón, Iván, 460
Boronat, Roc, 492
Borrego, Diana, 181
Borràs Rius, Albert, 210
Brazaola-Vicario, Aitor, 44
Briones Delgado, Alan, 306
Briones, Alan, 482
Brito, Constança, 360
Broncano Morgado, Fernando, 310
Buitrago López, Alejandro, 22, 140
Buitrago-Pérez, Marina, 314
BustamanteV, DiegoF, 242
- Caballero-Gil, Pino, 298, 384, 458
Cabuya-Padilla, Diego, 484
Calvo Ibañez, Albert, 450
Camara, Carmen, 244
Campo, Celeste, 264
Caro, Andres, 414
Caro, Andrés, 174, 231, 246
- Carrasco Mateos, Juan Atanasio, 220
Carrillo-Mondéjar, Javier, 135
Casado, Mario, 214
Casado-González, Alexia, 205
Castejón-Limas, Manuel, 13
Castellà-Roca, Jordi, 170, 319
Castro Ponce, Mario, 360
Cayuela Tudela, Alejandro David, 22
Cecilia, Andreu, 344
Chatterjee, Durba, 438
Clavijo-Herrera, Mauro, 42
Corcoba, Víctor, 294, 347
Corral Torruella, Guiomar, 306
Corral, Guiomar, 482
Costa-Calvoparra, Jaume, 330
Costa-Castelló, Ramon, 344
Criado-Lozano, Pablo A., 255
Cuesta Bartolomé, Belén, 22
- Dafonte, Carlos, 214
Daza, Vanesa, 56, 276, 492
de Bonrostro, Javier Pallarés, 392
de Catalunya, Centre Tecnològic, 194
de Cámara, Xabier Sáez, 154
de Fuentes, Jose Maria, 314
de José, Ignasi, 214
de Pedro, Luis, 52
De-Marcos, Luis, 436
del Pozo, Angel Pérez, 176
Di Bartolo, Agustín, 70, 414
Domingo-Ferrer, Josep, 95, 272
Doménech, Jordi, 144
Domínguez-Díaz, Adrián, 436
Domínguez-Vázquez, Paula, 18
Dorado, Julián, 92
Díaz-Verdejo, Jesús E., 464
- Escanez-Exposito, Daniel, 384, 458
Escobar, Santiago, 455, 462
Esparza, Oscar, 31
Estepa, Antonio, 226, 347, 464
Estepa, Rafael, 226, 464
Etxezarreta, Xabier, 400
- Fernandez-Gago, Carmen, 88

- Fernández González, Pablo, 310
 Fernández Iglesias, Diego, 90
 Fernández Maimó, Lorenzo, 124, 126
 Fernández-Medina Patón, Eduardo, 467
 Fernández-Medina, Eduardo, 78, 186, 242
 Fernández-Morales, E., 224
 Fernández-Robles, Laura, 13, 98
 Ferré-Queralt, Joan, 319
 Fidalgo, Eduardo, 13, 98
 Figueroa-Lorenzo, Santiago, 240
 Foronda-Pascual, Daniel, 244
- Gambra, Asier, 438
 Garabato, Daniel, 214
 García-Díaz, Jorge, 384
 García-Rubio, Carlos, 264
 García de Alcaraz Ruiz, Teresa, 22
 García Rodríguez, Pablo, 70, 174, 414
 García Teodoro, Pedro, 302
 García, Roberto, 294, 347
 García-Nogueiras, Carmen, 18
 García-Nogueiras, Iván, 18
 Garitano, Iñaki, 400
 Gaspar Medina-Arco, Joaquín, 148
 Gastó, Josep M., 170
 Gaul, Christopher, 13
 Gañán, Carlos H., 122
 Gil Pérez, Manuel, 48, 61
 Goiriz Seoane, Araceli, 196
 Gonzalez-Manzano, Lorena, 314
 González, Iván, 52
 González-Castro, Victor, 98
 González-Tablas, Ana I., 392
 Gosálvez White, Irene, 302
 Gris Sánchez, Itandehui, 22
 Guerrero-Higueras, Ángel Manuel, 205
 Guillen, Montserrat, 446
 Guillén-Mass, Jovan A., 442
 Gutiérrez Delgado, Mario, 160
 Gómez Carpena, Miguel, 423
- Haughton, Loya C., 13, 98
 Hernantes, Josune, 158, 240
 Hernández Ramos, José Luis, 216
 Hernández Serrano, Juan, 31
 Hernández, R., 224
 Hernández-Sánchez, Arturo, 455
 Herrera-Joancomartí, Jordi, 330
 Homaei, Mohammadhossein, 70, 174, 231, 246, 414
 Huertas Celdrán, Alberto, 61
 Huici, Daniel, 86
 Ibáñez Lissen, Luis, 513
- Ingeniero Torres, Plaza, 322
 Iturbe, Mikel, 400
 Izal Azcárate, Mikel, 476
- Jacob Taquet, Eduardo, 322
 Jarauta Sánchez, Javier, 220
 Jebreel, Najeeb, 95
 Jesús García-Molina, Fernando, 114
 Jesús Varela-Vaca, Ángel, 181
 Jimenez-Berenguel, Andrea, 264
 Jimeno Miguel, Carlos, 428, 476
 José Moreira-Pérez, Juan, 18
 Junquera-Sánchez, Javier, 285
 Justo Guillaumet, Joana, 306
- Kreso, Inda, 231
- Lage, Oscar, 44
 Lanza, Jorge, 423
 Lara-Gutierrez, Antonio, 88
 Larriva-Novo, Xavier, 160
 Laskurain, Unai, 274
 León, Olga, 144
 Lopez Trigo, Alberto, 70
 Lopez, Javier, 194
 López López, Gregorio, 184, 220, 290, 360
 López López, Álvaro Jesús, 220
 López Trigo, Alberto, 231
 López, Alberto, 246
 López, Marco, 353
 López-Pazos, Guillermo, 18
- Machaka, Valentine, 158, 240
 Madinabeitia, Germán, 464
 Mestre Vidal, Jorge, 26
 Magán-Carrión, Roberto, 114, 148, 442
 Manchón Válegas, Carlos, 22
 Manzano Caro, Eva, 310
 Mario Braga, Carlos, 78
 Martín-Faus, Isabel V., 144
 Martínez Pérez, Gregorio, 22
 Martínez-Herráiz, José-Javier, 436
 Masciopinto, Miguel, 18
 Matanza, Javier, 184
 Matellán-Olivera, Vicente, 205
 Matheu Garcia, Sara Nieves, 34
 Mayor, Vicente, 226
 Melendi, David, 294, 347
 Mena, Eduardo, 86
 Menasalvas Medina, Sandra, 22
 Mirjalili, Milad, 13
 Mogollón Gutiérrez, Óscar, 231
 Mogollón-Gutiérrez, Óscar, 414

- Montoro Aguilera, David, 140
 Morales Duque, Sergi, 338
 Moure-Garrido, Marta, 264
 Munteanu, Cristian R., 92
 Muñoz Heredia, Daniel, 181
 Muñoz Plaza, Frida, 22
 Muñoz, Vicente, 176
 Muñoz-Calle, Fco. Javier, 464
 Muñoz-Calle, Javier, 226
 Méndez García, Laura, 22
- Navarro Martínez, Álvaro, 34
 Nerín, Pau, 446
 Nespoli, Pantaleone, 48, 61
 Nóvoa, Francisco J., 90, 214
- Ogata, Kazuhiro, 462
 Oliva Bermejo, Francisco, 26
 Onieva, Jose A., 88
 Orduna Urrutia, Raúl, 428
 Ortega-Fernandez, Ines, 432
 Ortiz Rabella, Nil, 450
- Palacios Hielscher, Rafael, 290
 Palacios, Rafael, 220
 Parada, Javier, 194
 Pastor-Galindo, Javier, 22, 140
 Pastor-Vargas, R., 224
 Pazos, Alejandro, 92, 381
 Pañeda, Xabiel G., 294, 347
 Peguerols, Josep, 38, 144
 Pelayo-Benedet, Tomás, 122
 Perales Gómez, Ángel Luis, 124, 126
 Peris-Lopez, Pedro, 244
 Peso, Antonio, 56
 Pilgermann, Michael, 38
 Ponderada, Acumulación, 283
 Prado-Sánchez, Víctor-Pablo, 436
 Pujante Sáez, Jaime, 216
 Pérez-Fuente, Alejandro, 255
 Pérez-Jove, Rubén, 92
 Pérez-Vieites, Diego, 18
- Quirumbay Yagual, Daniel, 90
- Ramírez, José Carlos, 353
 Regueiro Senderos, Cristina, 322
 Reyes, Mario, 194
 Rezaei, Farzam, 52
 Riggio Diéguez, Carlos, 196
 Rioja, Unai, 438
 Rivera-Dourado, Martiño, 381
 Robles-Gómez, A., 224
- Roc Boronat, Carrer de, 276
 Rodrigues, Filipe, 360
 Rodríguez, Antton, 400
 Rodríguez Mondéjar, José Antonio, 220
 Rodríguez Pérez, Néstor, 220
 Rodríguez Vega, Marcos, 298
 Rodríguez, Ricardo J., 86
 Rodríguez-Gómez, Rafael A., 148
 Roldán-Gómez, José, 135
 Romero Ciudad, Eugenio, 467
 Romero, José-María, 482
 Romeu Casas, Marc, 165
 Román-García, Fernando, 31
 Ropa Muñoz, Antonio, 114
 Rosado, David G., 186, 242
 Rueda Torres, Jose Luis, 184
 Ruipérez-Valiente, José A., 22, 140
 Ruiz Chicano, Ignacio, 216
 Ruiz, Marc, 368
 Ruiz-Catalán, Jose L., 242
 Ruiz-Catalán, José L., 186
 Ruiz-Villafranca, Sergio, 135
 Ruíz Catalán, José Luis, 467
 Ràfols, Carla, 56, 492
- Salas Piñón, Julián, 338
 Santos-Olmo, Antonio, 186, 242, 467
 Sarmiento, Álvaro, 214
 Sarrapia, J., 224
 Seco Aguirre, Iñaki, 322
 Serrano, Manuel A., 78
 Sestelo, Marta, 152
 Shuaib Siddiqui, Muhammad, 450
 Sierra Granados, Joaquín, 467
 Sierra, Joaquin, 78
 Sigríst, Lukas, 184
 Skarmeta Gómez, Antonio Fernando, 34
 Solera-Cotanilla, Sonia, 160
 Soriente, Claudio, 176
 Suárez Mulero, José Francisco, 22
 Suárez-Bárcena, Ángel, 186, 467
 Sáez Moreno, Germán, 376
 Sánchez Pardo, Belén, 216
 Sánchez, David, 95
 Sánchez, Julia, 482
 Sánchez, Luis, 423
 Sánchez, Luis E., 186, 242
 Sánchez-Zas, Carmen, 160
- Tanveer, Waqar, 13
 Tarif, Mehran, 174
 Tejero, Juan Manuel, 22

Trujillo-Rasua, Rolando, 42
Tuset-Peiró, Pere, 38

Unibertsitatea, Mondragon, 154, 274, 400
Urquizu Gómez, Borja, 322
URV, Fundació, 170

Valencia Gil-Ortega, Agustín, 220
Valle, Pablo, 154
Vidal-Balboa, Pedro, 106
Vidiella, Pere, 38
Viejo, Alexandre, 170, 319
Villanueva, Nora M., 152
Vázquez-Naya, Jose, 92, 381

Xenakis, Christos, 381

Zaharia, Georgia, 314
Zola, Francesco, 428
Zurutuza, Urko, 274, 400

Ávila Vegas, Mar, 310
Ávila, Mar, 174, 246