



MÁSTER EN BIG DATA, TECNOLOGÍA Y ANALÍTICA AVANZADA

TRABAJO FIN DE MÁSTER

Detección de *fake news* a través de inteligencia
artificial

Autor: Ignacio López Soto

Director: Carlos Miguel Vallez Fernández

Madrid

Declaro, bajo mi responsabilidad, que el Proyecto presentado con el título

Detección de fake news a través de inteligencia artificial

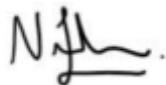
en la ETS de Ingeniería - ICAI de la Universidad Pontificia Comillas en el

curso académico 2022/23 es de mi autoría, original e inédito y

no ha sido presentado con anterioridad a otros efectos.

El Proyecto no es plagio de otro, ni total ni parcialmente y la información que ha sido

tomada de otros documentos está debidamente referenciada.



Fdo.: Ignacio López Soto

Fecha: 17/06/2025

Autorizada la entrega del proyecto

EL DIRECTOR DEL PROYECTO

Fdo.:

Fecha:



MÁSTER EN BIG DATA, TECNOLOGÍA Y ANALÍTICA AVANZADA

TRABAJO FIN DE MÁSTER

Detección de *fake news* a través de inteligencia
artificial

Autor: Ignacio López Soto

Director: Carlos Miguel Vallez Fernández

Madrid

DETECCIÓN DE FAKE NEWS A TRAVÉS DE INTELIGENCIA ARTIFICIAL

Autor: López Soto, Ignacio.

Director: Vallez Fernández, Carlos Miguel.

RESUMEN DEL PROYECTO

En este proyecto se estudia el uso de agentes y *Large Language Models* para la detección de *fake news* con el objetivo de mantener niveles de precisión de otros modelos de *machine learning*, pero aplicando las últimas tecnologías y añadiendo un componente de explicabilidad a las predicciones.

Palabras clave: Agente, *Fake news*, LLM, GenAI, Noticias falsas

1. Introducción

En la era digital, las *fake news* amenazan la credibilidad de la información. Muchas empresas como Google o Meta gastan decenas de millones de dólares al año [1] para combatir la desinformación. Por otro lado, muchas empresas afectadas por *fake news* llegan a gastar miles de millones de dólares en remediar el daño reputacional [2]. Este proyecto de fin de máster pretende emplear inteligencia artificial (IA en adelante) en su último exponente para facilitar el combate contra las *fake news* y sus negativas consecuencias.

Reducir los costes y aumentar la eficacia del *fact-checking* tendría un impacto transformador en la lucha contra la desinformación a gran escala. Actualmente, el proceso de verificación sigue siendo en gran medida manual, lo que limita su capacidad de respuesta frente a la rapidez con la que se propagan contenidos falsos. La automatización parcial del *fact-checking* mediante IA permitiría escalar significativamente las operaciones de verificación, haciendo que no solo grandes plataformas tecnológicas, sino también medios pequeños, ONG y actores individuales puedan acceder a herramientas robustas de verificación. Esta democratización del *fact-checking* contribuiría a una sociedad más informada, resiliente y menos vulnerable a la manipulación informativa.

2. Definición del proyecto

El objetivo principal de este proyecto es llevar a cabo una prueba de concepto para determinar la efectividad que podría tener un flujo de trabajo de agentes de IA para detectar *fake news*. Para lograr dicho objetivo, se plantean los siguientes subobjetivos que deberá conseguirse durante el desarrollo del proyecto:

- Explicar el conjunto de datos utilizado para el proyecto.

- Crear una metodología de evaluación rigurosa que pueda ser aplicada al conjunto de datos y que permita comparar los resultados con comparativas de rendimiento externos.
- Crear y definir un flujo de trabajo de agentes de IA que sea capaz de clasificar noticias como *fake news* correctamente.
- Evaluar los resultados del flujo de agentes de IA aplicando la metodología establecida en el segundo subobjetivo.
- Añadir un componente de explicabilidad de la herramienta.

3. Descripción del modelo

El modelo desarrollado en este proyecto se sustenta en una arquitectura de procesamiento de lenguaje natural diseñada para distinguir entre noticias verdaderas y falsas a partir de sus características textuales y contextuales. Para entrenar y evaluar el sistema, se utilizaron dos conjuntos de datos públicos obtenidos de la plataforma Kaggle, que proporcionan una base diversa tanto en idioma como en procedencia geográfica de las noticias.

El primer conjunto de datos [9] está compuesto por artículos en inglés publicados entre marzo de 2015 y febrero de 2018, provenientes de medios internacionales, con un enfoque principal en eventos ocurridos en Estados Unidos. Este set se divide en dos tablas: una que contiene 21.417 noticias auténticas y otra con 23.481 noticias identificadas como falsas. Ambas comparten una estructura común con columnas que incluyen título, texto, tema y fecha de publicación. En el caso de las noticias verdaderas, los temas se limitan a “politicsNews” y “worldnews”, mientras que en el caso de las noticias falsas se encuentran categorías más diversas como “Politics”, “Government News” o “US_News”, lo cual refleja una mayor dispersión temática. La fecha constituye un atributo clave en el diseño del sistema, ya que permite asegurar que la evaluación de cada artículo no esté influida por información posterior a su publicación, lo que resulta esencial para simular condiciones reales de verificación.

El segundo conjunto de datos [10] contiene noticias en español publicadas entre enero de 2018 y diciembre de 2022. Este dataset también se divide en dos tablas: una con 33.351 artículos verdaderos y otra con 23.880 artículos falsos. Las columnas incluidas son ID, etiqueta de veracidad, título, descripción y fecha. Aunque presenta un formato diferente al del conjunto en inglés, se realizó una adaptación para unificarlos, asimilando los campos y utilizando el tema genérico “Spanish politics” para mantener la coherencia estructural durante el procesamiento. Una diferencia relevante entre ambos conjuntos radica en el origen de las fake news: mientras que el dataset en inglés se compone de

noticias falsas verificadas profesionalmente, el dataset en español contiene artículos generados mediante manipulación de información veraz y producción automatizada con herramientas de inteligencia artificial. Esta variación introduce un nivel adicional de complejidad, ya que no todas las falsificaciones responden a los mismos patrones textuales o discursivos.

El sistema predictivo se basa en un modelo de lenguaje de alto rendimiento, Claude-3-5-sonnet-20241022, desarrollado por *Anthropic*, que ha sido seleccionado por su capacidad para ofrecer resultados sólidos sin requerir procesos adicionales de fine tuning. Para maximizar la consistencia en las respuestas, el modelo se ejecuta con una temperatura baja (0.1). Este agente inteligente ha sido configurado mediante las librerías de código abierto *langchain* y *langgraph*, que proporcionan la infraestructura para integrar el modelo con un conjunto de herramientas diseñadas específicamente para la tarea de verificación. La interacción con el modelo se rige por un *prompt* cuidadosamente diseñado que incorpora varias secciones orientadas a asegurar el comportamiento experto del agente.

El *prompt* comienza con una atribución de personalidad en la que se especifica que el modelo actúa como un verificador profesional de hechos que trabaja para una red social. Esta técnica, conocida como *role priming*, ha demostrado ser efectiva para inducir comportamientos lingüísticos y decisionales adecuados al contexto profesional simulado. A continuación, se presenta una definición explícita del objetivo: determinar si una noticia es verdadera o falsa basándose en su título, contenido, tema y fecha. Para cumplir esta tarea, el modelo tiene acceso a tres herramientas complementarias que se presentan de forma estructurada, cada una con una función claramente diferenciada. Asimismo, se define una estructura de salida binaria (“*true*” o “*fake*”) que facilita la evaluación automatizada del rendimiento del sistema. El *prompt* incluye además recomendaciones metacognitivas como planificar exhaustivamente antes de utilizar cada herramienta y reflexionar sobre los resultados obtenidos, lo cual promueve una secuencia de razonamiento más estructurada, aun cuando el modelo no posea capacidades reflexivas en sentido estricto. Finalmente, se exige una justificación clara de la decisión tomada, lo que refuerza la transparencia del sistema y permite auditar el proceso de verificación.

El conjunto de herramientas disponible para el agente representa una aproximación multifacética que emula los métodos utilizados por verificadores humanos. La primera herramienta corresponde a una base de datos de conocimiento construida a partir del conjunto de noticias verdaderas en inglés. Cada artículo ha sido vectorizado utilizando la librería *OpenAIEmbeddings* con el modelo *text-embedding-ada-002*, y almacenado en una base vectorial implementada con *Chroma*. Esta herramienta permite al agente

recuperar artículos similares al que está evaluando, comparando vectores mediante medidas de distancia. El sistema devuelve los cinco artículos más relevantes, siempre que hayan sido publicados antes que el artículo evaluado, con el fin de evitar la utilización de información posterior en la toma de decisiones.

La segunda herramienta permite realizar búsquedas en internet limitadas temporalmente. El agente formula una consulta basada en fragmentos del artículo y utiliza una API de Google para obtener los primeros cinco resultados relevantes, asegurándose de que todos provengan de fechas anteriores a la del artículo. Este recurso permite al modelo contrastar hechos específicos mencionados en el texto con otras fuentes accesibles, reforzando su capacidad para detectar afirmaciones potencialmente falsas o manipuladas.

Finalmente, se incluye un análisis estilístico realizado mediante el modelo Gemini-1.5-pro. A través de un prompt específico, el sistema analiza diversos indicadores que suelen estar presentes en noticias falsas, como el uso de lenguaje emocional o sensacionalista, sesgos políticos, calidad de redacción, presencia y tratamiento de entidades nombradas, y uso de tácticas de manipulación argumentativa. La respuesta de esta herramienta sigue un formato JSON estructurado que permite una interpretación sistemática del estilo discursivo del artículo evaluado.

En conjunto, el diseño del modelo combina precisión técnica, buenas prácticas en ingeniería de prompts y una infraestructura flexible que permite integrar múltiples fuentes de evidencia. Esta estrategia permite una evaluación robusta de la veracidad de las noticias, aplicable tanto a contenidos en inglés como en español, y adaptable a contextos dinámicos de verificación automatizada en plataformas digitales.

4. Resultados

En este capítulo se detalla la metodología empleada para la extracción de resultados del agente de clasificación de noticias, así como las métricas de evaluación utilizadas y los resultados obtenidos para artículos en inglés y español.

El tiempo de procesamiento serial mediante API de los modelos evaluados resultó ser excesivo, especialmente al utilizar el agente junto con sus herramientas, alcanzando hasta 30 segundos por artículo. Para optimizar este proceso, se desarrolló un script que permite el procesamiento paralelo de múltiples artículos. Este script carga los conjuntos de datos, invoca al agente para la clasificación y ejecuta múltiples hilos con instancias independientes del agente para evitar contaminación de contexto entre artículos. Además, se implementó lógica para evitar la reprocesamiento de artículos ya

clasificados. Gracias a estas mejoras, el tiempo total para procesar 600 artículos se redujo de más de seis horas a 90 minutos.

Se emplearon las métricas estándar para tareas de clasificación binaria: precisión, recall, F1-score, accuracy y ROC AUC. Dado que el conjunto de evaluación fue balanceado entre artículos verdaderos y falsos, el objetivo fue minimizar la cantidad de noticias falsas clasificadas como verdaderas, sin censurar en exceso las noticias verídicas. El criterio del autor da prioridad a evitar la censura de artículos verdaderos y, en segundo lugar, a reducir la propagación de noticias falsas.

La muestra final evaluada consistió en 397 artículos en inglés y 202 en español, distribuidos equitativamente entre verdaderos y falsos. En el caso de los artículos en inglés, el agente obtuvo resultados sobresalientes: precisión del 92%, recall del 100%, F1-score del 96% y accuracy del 96%. Para los artículos en español, los valores disminuyen: precisión del 89%, recall del 82% y F1-score del 85%. La exactitud general en español fue un 12% inferior a la obtenida en inglés. Esta pérdida se atribuye, al menos en parte, a la forma en que se generaron las noticias falsas en español, que, al ser construidas artificialmente, no reflejan con fidelidad los patrones reales de desinformación.

Los ejemplos cualitativos permiten observar cómo el agente realiza su clasificación mediante un enfoque de triangulación: análisis estilístico, verificación de hechos y búsqueda contextual. En los casos exitosos, el agente detecta un estilo informativo riguroso, fuentes confiables y hechos verificables. En cambio, los artículos correctamente identificados como falsos muestran señales de lenguaje emocional, sesgo explícito, falta de citas y mezcla de opinión con hechos sin verificación.

Sin embargo, en los errores de clasificación se identifican patrones importantes. En un caso de falso positivo en inglés, el artículo es clasificado como verdadero a pesar de contener elementos sensacionalistas y sesgados. El agente justifica su decisión en base a la veracidad de los hechos descritos, aunque reconoce el tono emocional y la falta de equilibrio. Este comportamiento se repite en otros errores similares: si los hechos son verificables, el agente tiende a clasificarlos como verdaderos, incluso si el estilo narrativo compromete su objetividad.

Para los errores en español, en cambio, no se identifica un patrón tan claro. Un ejemplo muestra un artículo verdadero sobre la posible rentabilidad económica para la Iglesia si los restos de Franco se trasladaran a La Almudena, que el agente clasifica como falso por considerarlo especulativo y sin respaldo empírico. En contraste, también se observan artículos falsos clasificados como verdaderos, como uno que informa sobre un debate educativo en el Congreso, donde el agente valida hechos comprobables sin detectar la manipulación más sutil del contenido.

El agente muestra un desempeño sólido en la clasificación de noticias en inglés, apoyado por la calidad y estructura de los artículos analizados. Para el español, la menor calidad del corpus y las características distintas de los artículos falsos dificultan su detección. El análisis de ejemplos pone en evidencia que el agente prioriza la verificación de hechos por encima del estilo narrativo, lo que en ocasiones conduce a clasificaciones erróneas cuando el contenido es veraz, pero presenta señales propias de desinformación o manipulación.

5. Conclusiones

La investigación valida la viabilidad de un enfoque basado en agentes de IA para la clasificación de artículos periodísticos, destacando el uso eficiente de datos preprocesados y la atención en el diseño del flujo de trabajo. La inclusión de múltiples modelos (Claude 3.5 Sonnet y Gemini 1.5 Pro) permitió robustecer los resultados mediante triangulación, aumentando la resiliencia del sistema ante distintas características textuales.

El uso de filtrado temporal estricto evitó el “data leakage”, simulando un entorno realista donde los agentes solo acceden a información previa a la fecha de publicación. Este diseño favorece la trazabilidad y objetividad, esenciales en entornos periodísticos.

Además, el procesamiento paralelo demostró la escalabilidad del prototipo, y el enfoque de agentes ofreció explicabilidad superior a la de modelos tradicionales, aumentando la transparencia y confianza en las decisiones del sistema. El modelo también mostró capacidad de generalización ante nuevos conjuntos de datos, lo cual refuerza su aplicabilidad en contextos variados.

El sistema alcanzó un desempeño excelente con una precisión del 96 % en artículos en inglés y 84 % en español, además de una alta capacidad discriminativa (ROC AUC: 94 % y 82 %, respectivamente). Destacó especialmente en la detección de noticias verdaderas, filtrando eficazmente falsedades, aunque el set español, compuesto por noticias falsas artificiales, limitó la validez de esos resultados.

Comparado con enfoques basados en transformadores evaluados “in-domain”, que tienden a perder precisión al generalizar, el sistema mostró mayor robustez con solo un 12 % de caída en escenarios cambiantes, frente a pérdidas de hasta 28 % en modelos tradicionales.

Operativamente, el sistema procesa artículos en 30 segundos de forma secuencial y 6 segundos en paralelo, con un coste estimado de 0,02 € por artículo, viable para aplicaciones en producción.

En conjunto, los resultados evidencian que el enfoque de agentes no solo es competitivo en términos cuantitativos, sino que añade valor mediante explicabilidad, escalabilidad y adaptabilidad a datos diversos.

FAKE NEWS DETECTION THROUGH ARTIFICIAL INTELLIGENCE

Autor: López Soto, Ignacio.

Director: Vallez Fernández, Carlos Miguel.

ABSTRACT

This Project studies the use of AI agents and Large Language Models for the detection of fake news, with the objective of maintaining accuracy levels of other machine learning models but applying the latest technologies and adding an explainability factor to the model classifications.

Key words: Agent, Fake news, LLM, GenAI

1. Introduction

In the digital age, fake news poses a serious threat to the credibility of information. Companies like Google and Meta spend tens of millions of dollars each year [1] to combat misinformation. On the other hand, many companies affected by fake news end up spending billions of dollars to repair reputational damage [2]. This master's thesis project aims to leverage artificial intelligence (hereafter AI) at its most advanced stage to support the fight against fake news and its harmful consequences.

Reducing costs and increasing the efficiency of fact-checking could have a transformative impact on the large-scale battle against misinformation. Currently, the verification process remains largely manual, limiting its ability to respond to the speed at which false content spreads. The partial automation of fact-checking through AI would enable verification operations to scale significantly, allowing not only large tech platforms but also smaller media outlets, NGOs, and individual actors to access robust verification tools. This democratization of fact-checking would contribute to a more informed, resilient society, less vulnerable to informational manipulation.

2. Definition of the project

The main objective of this project is to carry out a proof of concept to determine the potential effectiveness of an AI agent workflow for detecting fake news. To achieve this goal, the following sub-objectives must be accomplished during the development of the project:

- Describe the dataset used in the project.
- Develop a rigorous evaluation methodology that can be applied to the dataset and allows for comparison with external performance benchmarks.

- Design and define an AI agent workflow capable of correctly classifying news articles as fake news.
- Evaluate the performance of the AI agent workflow using the methodology established in the second sub-objective.
- Add an explainability component to the tool.

3. Description of the model

The model developed in this project is based on a natural language processing architecture designed to distinguish between true and false news based on their textual and contextual features. To train and evaluate the system, two public datasets obtained from the Kaggle platform were used, providing a diverse foundation in both language and geographic origin of the news.

The first dataset [9] consists of articles in English published between March 2015 and February 2018, coming from international media outlets, with a primary focus on events that occurred in the United States. This set is divided into two tables: one containing 21,417 genuine news articles and another with 23,481 articles identified as false. Both share a common structure with columns that include title, text, topic, and publication date. In the case of true news, the topics are limited to “politicsNews” and “worldnews,” whereas false news includes more diverse categories such as “Politics,” “Government News,” or “US_News,” reflecting a broader thematic dispersion. The date is a key attribute in the system's design, as it ensures that the evaluation of each article is not influenced by information published after its release, which is essential for simulating real-world verification conditions.

The second dataset [10] contains news articles in Spanish published between January 2018 and December 2022. This dataset is also divided into two tables: one with 33,351 true articles and another with 23,880 false articles. The included columns are ID, veracity label, title, description, and date. Although it presents a different format from the English dataset, an adaptation was performed to unify them by aligning the fields and using the generic topic “Spanish politics” to maintain structural consistency during processing. A relevant difference between the two datasets lies in the origin of the fake news: while the English dataset comprises professionally verified fake news, the Spanish dataset contains articles generated through manipulation of truthful information and automated production using artificial intelligence tools. This variation introduces an additional level of complexity, as not all fabrications follow the same textual or discursive patterns.

The predictive system is based on a high-performance language model, Claude-3-5-sonnet-20241022, developed by Anthropic, which was selected for its ability to deliver robust results without requiring additional fine-tuning processes. To maximize

consistency in the responses, the model is run with a low temperature setting (0.1). This intelligent agent has been configured using the open-source libraries LangChain and LangGraph, which provide the infrastructure to integrate the model with a set of tools specifically designed for the verification task. Interaction with the model is governed by a carefully crafted prompt that includes several sections aimed at ensuring the agent's expert behavior.

The prompt begins with a personality attribution specifying that the model acts as a professional fact-checker working for a social media platform. This technique, known as role priming, has proven effective in inducing linguistic and decision-making behaviors appropriate to the simulated professional context. Next, an explicit definition of the objective is presented: to determine whether a news article is true or false based on its title, content, topic, and date. To accomplish this task, the model has access to three complementary tools presented in a structured way, each with a clearly differentiated function. A binary output structure (“true” or “fake”) is also defined to facilitate the automated evaluation of the system’s performance. The prompt further includes metacognitive recommendations such as thoroughly planning before using each tool and reflecting on the results obtained, which promotes a more structured reasoning sequence, even if the model does not possess reflective capabilities in a strict sense. Finally, a clear justification of the decision is required, reinforcing the system’s transparency and enabling auditability of the verification process.

The toolset available to the agent represents a multifaceted approach that emulates methods used by human fact-checkers. The first tool is a knowledge database built from the set of true English news articles. Each article has been vectorized using the OpenAIEmbeddings library with the text-embedding-ada-002 model and stored in a vector database implemented with Chroma. This tool allows the agent to retrieve articles similar to the one being evaluated by comparing vectors through distance measures. The system returns the five most relevant articles, provided they were published before the evaluated article, in order to avoid using later information in the decision-making process.

The second tool enables time-constrained internet searches. The agent formulates a query based on fragments of the article and uses a Google API to obtain the top five relevant results, ensuring they all come from dates earlier than that of the article. This resource allows the model to cross-check specific claims mentioned in the text with other accessible sources, enhancing its ability to detect potentially false or manipulated assertions.

Finally, a stylistic analysis is included, conducted using the Gemini-1.5-pro model. Through a specific prompt, the system analyzes various indicators commonly present in fake news, such as the use of emotional or sensationalist language, political bias, writing

quality, presence and treatment of named entities, and the use of argumentative manipulation tactics. The output from this tool follows a structured JSON format that enables systematic interpretation of the article's discursive style.

Altogether, the model's design combines technical precision, best practices in prompt engineering, and a flexible infrastructure that allows the integration of multiple sources of evidence. This strategy enables a robust evaluation of news veracity, applicable to content in both English and Spanish, and adaptable to dynamic verification contexts on digital platforms.

4. Results

In this chapter, the methodology used for extracting results from the news classification agent is detailed, as well as the evaluation metrics employed, and the results obtained for articles in English and Spanish.

The serial processing time via API for the evaluated models turned out to be excessive, especially when using the agent along with its tools, reaching up to 30 seconds per article. To optimize this process, a script was developed that allows for the parallel processing of multiple articles. This script loads the datasets, invokes the agent for classification, and runs multiple threads with independent instances of the agent to avoid context contamination between articles. In addition, logic was implemented to avoid reprocessing already classified articles. Thanks to these improvements, the total time to process 600 articles was reduced from over six hours to 90 minutes.

Standard metrics for binary classification tasks were used: precision, recall, F1-score, accuracy, and ROC AUC. Since the evaluation set was balanced between true and false articles, the goal was to minimize the number of false articles classified as true, without excessively censoring true news. The author's criterion prioritizes avoiding censorship of true articles, and secondly, reducing the spread of false news.

The final sample evaluated consisted of 397 articles in English and 202 in Spanish, evenly distributed between true and false. For English articles, the agent achieved outstanding results: 92% precision, 100% recall, 96% F1-score, and 96% accuracy. For Spanish articles, the values decrease: 89% precision, 82% recall, and 85% F1-score. Overall accuracy in Spanish was 12% lower than that obtained in English. This loss is attributed, at least in part, to how the false news in Spanish was generated, which, being artificially constructed, does not faithfully reflect real disinformation patterns.

The qualitative examples allow us to observe how the agent performs its classification using a triangulation approach: stylistic analysis, fact-checking, and contextual search. In successful cases, the agent detects a rigorous informational style, reliable sources, and

verifiable facts. In contrast, articles correctly identified as false show signs of emotional language, explicit bias, lack of citations, and a mixture of opinion with unverified facts.

However, important patterns are identified in misclassification errors. In one English false positive case, the article is classified as true despite containing sensationalist and biased elements. The agent justifies its decision based on the veracity of the described facts, even though it recognizes the emotional tone and lack of balance. This behavior is repeated in other similar errors: if the facts are verifiable, the agent tends to classify them as true, even if the narrative style compromises objectivity.

For errors in Spanish, however, no such clear pattern is identified. One example shows a true article about the potential economic profitability for the Church if Franco's remains were moved to La Almudena, which the agent classifies as false due to its speculative nature and lack of empirical support. In contrast, false articles classified as true are also observed, such as one reporting on an educational debate in Congress, where the agent validates verifiable facts without detecting the more subtle manipulation of the content.

The agent shows strong performance in classifying English-language news, supported by the quality and structure of the analyzed articles. For Spanish, the lower quality of the corpus and the different characteristics of false articles make detection more difficult. The analysis of examples highlights that the agent prioritizes fact verification over narrative style, which at times leads to misclassifications when the content is truthful but exhibits traits typical of misinformation or manipulation.

5. Conclusions

The research validates the feasibility of an AI agent-based approach for the classification of journalistic articles, highlighting the efficient use of pre-processed data and attention to workflow design. The inclusion of multiple models (Claude 3.5 Sonnet and Gemini 1.5 Pro) strengthened the results through triangulation, increasing the system's resilience to different textual features.

Strict temporal filtering was used to prevent "data leakage," simulating a realistic environment where agents only access information prior to the publication date. This design favors traceability and objectivity, which are essential in journalistic settings. Furthermore, parallel processing demonstrated the scalability of the prototype, and the agent-based approach offered superior explainability compared to traditional models, enhancing the transparency and trust in the system's decisions. The model also showed generalization capability when faced with new datasets, which reinforces its applicability in varied contexts.

The system achieved excellent performance with an accuracy of 96% on English articles and 84% on Spanish ones, as well as a high discriminative ability (ROC AUC: 94% and 82%, respectively). It particularly excelled in detecting true news, effectively filtering out falsehoods, although the Spanish set, composed of artificially generated fake news, limited the validity of those results.

Compared to transformer-based approaches evaluated “in-domain,” which tend to lose accuracy when generalizing, the system showed greater robustness with only a 12% drop in changing scenarios, versus losses of up to 28% in traditional models. Operationally, the system processes articles in 30 seconds sequentially and 6 seconds in parallel, with an estimated cost of €0.02 per article, making it viable for production applications.

Overall, the results demonstrate that the agent-based approach is not only competitive in quantitative terms, but also adds value through explainability, scalability, and adaptability to diverse data.

Índice de la memoria

Capítulo 1. Introducción	2
1.1 Motivación del proyecto	2
1.2 Objetivos del proyecto	2
1.3 Metodología del trabajo	3
1.4 Estado de la cuestión.....	4
1.5 Recursos a emplear	5
Capítulo 2. Descripción del modelo desarrollado.....	6
2.1 Datos	6
2.2 Modelo predictivo	6
2.2.1 Agente.....	7
2.2.2 Herramientas.....	10
Capítulo 3. Análisis de resultados.....	13
3.1 Metodología de extracción de resultados	13
3.2 Definición de métricas	14
3.3 Resultados	14
Capítulo 4. Conclusiones.....	27
4.1 Conclusiones sobre la metodología.....	27
4.2 Conclusiones sobre los resultados.....	28
4.3 Recomendaciones para futuros estudios	29
Capítulo 5. Bibliografía.....	32

ÍNDICE DE CONTENIDOS

Tabla 1. Matriz de confusión del modelo.....	14
Ilustración 1. Curva ROC del modelo.....	15

Capítulo 1. INTRODUCCIÓN

1.1 MOTIVACIÓN DEL PROYECTO

En la era digital, las fake news amenazan la credibilidad de la información. Muchas empresas como Google o Meta gastan decenas de millones de dólares al año [1] para combatir la desinformación. Por otro lado, muchas empresas afectadas por fake news llegan a gastar miles de millones de dólares en remediar el daño reputacional [2]. Este proyecto de fin de máster pretende emplear inteligencia artificial (IA en adelante) en su último exponente para facilitar el combate contra las fake news y sus negativas consecuencias.

Reducir los costes y aumentar la eficacia del *fact-checking* tendría un impacto transformador en la lucha contra la desinformación a gran escala. Actualmente, el proceso de verificación sigue siendo en gran medida manual, lo que limita su capacidad de respuesta frente a la rapidez con la que se propagan contenidos falsos. La automatización parcial del *fact-checking* mediante IA permitiría escalar significativamente las operaciones de verificación, haciendo que no solo grandes plataformas tecnológicas, sino también medios pequeños, ONG y actores individuales puedan acceder a herramientas robustas de verificación. Esta democratización del *fact-checking* contribuiría a una sociedad más informada, resiliente y menos vulnerable a la manipulación informativa.

1.2 OBJETIVOS DEL PROYECTO

El objetivo principal de este proyecto es llevar a cabo una prueba de concepto para determinar la efectividad que podría tener un flujo de trabajo de agentes de IA para detectar *fake news*. Para lograr dicho objetivo, se plantean los siguientes subobjetivos que deberá conseguirse durante el desarrollo del proyecto:

- Explicar el conjunto de datos utilizado para el proyecto.
- Crear una metodología de evaluación rigurosa que pueda ser aplicada al conjunto de datos y que permita comparar los resultados con comparativas de rendimiento externos.
- Crear y definir un flujo de trabajo de agentes de IA que sea capaz de clasificar noticias como *fake news* correctamente.
- Evaluar los resultados del flujo de agentes de IA aplicando la metodología establecida en el segundo subobjetivo.
- Añadir un componente de explicabilidad de la herramienta.

1.3 METODOLOGÍA DEL TRABAJO

En primer lugar, se estudia el conjunto de datos que será entrada del modelo. Este paso incluye un análisis exploratorio, su preprocesado y la posible creación de nuevas variables con *feature engineering*.

En segundo lugar, se diseñará, y posteriormente creará, un flujo de trabajo de agentes de IA que sea capaz de interpretar noticias, extraer sentimientos, juzgarlas y clasificarlas. Llevar esta tarea a cabo requiere una precisa definición de las personalidades, tareas y herramientas que tendrá cada agente, así como su interconexión en el flujo de trabajo.

En paralelo, se definirá la metodología de evaluación del modelo para lo que se seguirá la consigna básica del *machine learning*, no evaluar un modelo con datos con los que se haya entrenado. Para ello, se restringirá el acceso de los agentes a la base de conocimiento para que no puedan leer información sobre el texto que estén intentando clasificar.

Además, para evaluar el modelo, se definen las métricas con las que medir la precisión. Principalmente se comparará la precisión de acierto del modelo, su matriz de confusión, y otras métricas habituales en problemas de clasificación.

El último paso consiste en extraer una justificación que de explicabilidad y credibilidad a la clasificación.

1.4 ESTADO DE LA CUESTIÓN

La rápida propagación de la desinformación en las redes sociales ha convertido la detección de *fake news* en un desafío importante para el procesamiento de lenguaje natural (NLP) y el *machine learning* (ML). Recientes avances en IA han mejorado significativamente la posibilidad de combatir este problema con modelos basados en transformadores como BERT, XLNET y RoBERTa liderando los avances. Estos modelos aprovechan mecanismos de atención para capturar relaciones semánticas y contextuales complejas dentro del texto. Esto los ha llevado a conseguir precisiones casi perfectas, con un 98% de evaluación F1 ([3], [4] y [5]). Otras tecnologías como los *Large Language Models (LLMs)* como LLaMa 3.2-1B han demostrado mejorar (de 50% a 71% de precisión) a través de *fine-tuning* [6].

Más allá de soluciones basadas solamente en texto, estrategias multimodales y basadas en grafos han emergido para integrar texto con imágenes y funciones particulares de las redes sociales, usando redes neuronales convolucionales para extraer información visual y redes neuronales de grafos para modelar las relaciones entre usuarios, publicaciones y patrones de difusión ([3], [4] y [5]). Esta metodología se ve complementada a través de la verificación de noticias contra “pruebas” con la ayuda de motores de búsqueda o conjuntos de datos como FEVER (185.445 ejemplos) y FACTIFY-5WQA (391,041 ejemplos) [7].

Modelos ensamblados elevan aún más la precisión combinando predicciones de varios modelos para mitigar debilidades individuales. Por ejemplo, se consiguió un 99% de precisión al ensamblar los modelos *random forest*, BERT, GRU y LSTM sobre el conjunto de datos WELFake [8].

A pesar de estas asombrosas métricas, sigue habiendo dificultades. Los sistemas de detección en tiempo real requieren una baja latencia, la generalización entre conjuntos de datos se mantiene difícil (con métodos tradicionales basados en *tokens* bajando hasta un 28%

de precisión) y los sesgos de los conjuntos de datos de entrenamiento requieren una solución [6].

Queda claro que existen muchas metodologías que consiguen muy buenas precisiones, pero no se han encontrado artículos que pretendan dar solución a este problema con agentes de IA, los cuales podrían ser la solución para brindar escalabilidad a una solución tecnológica de estos problemas.

1.5 RECURSOS A EMPLEAR

Para llevar a cabo el proyecto, se ha trabajado en Python, versión 3.12.2. En concreto, para trabajar con los datos se ha empleado pandas, versión 2.2.3. Para el uso de los agentes se ha utilizado *langchain*, versión 0.3.25, y *langgraph*, versión 0.4.8

Como LLM se han utilizado varios modelos para diferentes funciones, entre ellos están *Claude-3-5-sonnet-20241022* de *Anthropic*, y *Gemini-1.5-pro* de *Google*. Por último, para *embeddings*, se ha utilizado *text-embedding-ada-002* de *OpenAI*.

Capítulo 2. DESCRIPCIÓN DEL MODELO

DESARROLLADO

2.1 DATOS

Para la ejecución de este proyecto, se han utilizado dos sets de datos públicos, en concreto obtenidos desde *Kaggle*, la famosa web de ciencia de datos. El primer set de datos [9], contiene dos tablas en formato csv. La primera, *true.csv*, contiene 21.417 artículos validados como verdaderos. La segunda, *false.csv*, contiene 23.481 artículos validados como falsos. Ambas tablas se componen de las siguientes columnas: Título, Texto, Tema, Fecha. El set de datos contiene artículos entre marzo de 2015 y febrero de 2018. Todos estos artículos son de medios internacionales y mayoritariamente centrados en eventos de Estados Unidos.

Título contiene el titular de la noticia, y texto contiene el cuerpo de la noticia. Solamente hay dos temas en el set de datos verdadero, “*politicsNews*”, y “*worldnews*”. En el set de datos falsos, hay los siguientes temas: “*News*”, “*Politics*”, “*Government News*”, “*Left-news*”, “*US_News*”, “*Middle-east*”. La fecha, es un campo clave para la ejecución del proyecto ya que servirá para evitar utilizar información proveniente de fechas posteriores a la del artículo para predecir si este es verdadero o falso.

El segundo set de datos [10], contiene dos tablas también, en formato csv, con 33.351 artículos verdaderos y 23.880 artículos falsos. Ambas tablas se componen de las siguientes columnas: ID, *Label*, Título, Descripción, y Fecha. Este set de datos contiene noticias españolas publicadas entre enero de 2018 y diciembre de 2022.

Estas columnas se asemejan lo suficiente a las del set de datos inglés, así que para facilitar el procesamiento se convierten al formato del inglés, utilizando como tema “Spanish politics”.

Por último, cabe destacar que mientras el set de datos inglés incluye fake news reales, verificadas por servicios de *fact-checking* profesionales, el set de datos español incluye fake news que han sido creadas alterando datos de las noticias originales y generando nuevas a través de inteligencia artificial.

2.2 *MODELO PREDICTIVO*

En este proyecto, se ha utilizado un agente de IA, al que se le han proporcionado varias herramientas a través de las librerías de código abierto *langgraph* y *langchain*. A continuación, se describen todos los aspectos relevantes.

2.2.1 AGENTE

El agente se compone de tres partes, el modelo, el *prompt*, y las herramientas.

El modelo utilizado, se trata de *Claude-3-5-sonnet-20241022* de *Anthropic*. Este es suficientemente avanzado como para no necesitar de técnicas de *fine tuning* para conseguir unos buenos resultados. Además, el modelo se inicializa con una temperatura baja (0,1) con el objetivo de conseguir consistencia en sus respuestas.

El *prompt* utilizado se compone de las siguientes partes:

- **Atribución de la personalidad:** *“You are an experienced fact checker working for a social network.”*
- **Descripción del objetivo:** *“Your task is to determine whether a given news article is true or fake news based on its title, content, and subject.”*
- **Detalles de la tarea y herramientas disponibles:** *“You will be provided with the title, the full text, the subject, and the date of the article.*

To help you assess the article, you are provided with the following tools:

1. ``get_related_news_from_knowledge_base``: *Find related news articles from a knowledge base that contains verified articles that could be related to the article you are evaluating.*

2. *`time_aware_search`*: Perform an internet search for news articles related to the subject of the article.

3. *`analyze_article_style`*: Your coworker will analyze the style of the article to determine if it is consistent with typical news articles.”

- **Definición de la respuesta final:** “After evaluating the article, respond with either 'true' if you believe the article reports factual information or 'fake' if you suspect it contains misinformation or is entirely fabricated.”
- **Aclaraciones finales:** “You must ensure accuracy, consistency and completeness in your evaluation.

If you are unsure, you can ask for more information or perform additional searches using the provided tools.

Always provide a clear and concise explanation of your reasoning.

You must use the tools provided to gather information and make your decision.

You MUST plan extensively before each tool call, and reflect extensively on the outcome of the tool calls.”

El diseño del *prompt* presentado evidencia una aplicación rigurosa de buenas prácticas en la ingeniería de *prompts* orientada al uso de modelos de lenguaje en tareas de verificación de información. Su estructura modular y progresiva permite al modelo asumir un rol especializado, comprender con claridad los objetivos de la tarea y actuar con criterio y responsabilidad durante la ejecución.

2.1.1.1 Atribución de personalidad experta

La primera sección del *prompt* realiza una atribución de rol que cumple una doble función: por un lado, especializa el comportamiento del modelo activando patrones lingüísticos y procedimentales propios del ámbito del *fact-checking*; por otro, introduce un marco institucional que orienta las respuestas hacia la responsabilidad, la imparcialidad y la defensa del interés público. Esta técnica, conocida como *role priming*, se ha mostrado eficaz para inducir respuestas más precisas, consistentes y adaptadas al contexto profesional simulado.

2.1.1.2. Claridad en la definición del objetivo

La descripción explícita de la tarea aporta concreción y elimina ambigüedades. El modelo entiende desde el inicio qué se espera de él, reduciendo así la posibilidad de respuestas genéricas o fuera de contexto. Este principio de claridad es fundamental en sistemas autónomos que deben tomar decisiones basadas en múltiples evidencias.

2.1.1.3. Listado estructurado de herramientas disponibles

La inclusión de herramientas específicas, presentadas de forma numerada y con funciones claramente diferenciadas, dota al modelo de una capacidad de razonamiento instrumental.

2.1.1.4. Definición binaria de la respuesta final

El uso de una decisión cerrada (“*true*” o “*fake*”) proporciona una estructura clara de salida que facilita la evaluación automática del rendimiento del agente. Esta forma de codificación de la respuesta es especialmente útil en sistemas que deben integrarse en flujos automatizados de moderación de contenido o anotación de bases de datos.

2.1.1.5. Instrucciones metacognitivas y de comportamiento

La inclusión de recomendaciones como “*plan extensively before each tool call*” y “*reflect extensively on the outcome of the tool calls*” introduce un componente metacognitivo que fomenta la autorregulación del modelo. Aunque los LLM no poseen consciencia ni reflexión real, estas instrucciones tienden a inducir cadenas de razonamiento más elaboradas y justificadas, mejorando la trazabilidad y la solidez de las decisiones tomadas. Del mismo modo, la exigencia de justificar las respuestas (“*Always provide a clear and concise explanation of your reasoning*”) promueve una mayor transparencia y legibilidad, cualidades esenciales en sistemas de IA explicables.

2.2.2 HERRAMIENTAS

El agente ha recibido tres herramientas distintas que en su conjunto representa una aproximación multi-estratégica que imita el comportamiento de los verificadores humanos y permite al modelo triangular evidencias desde distintas dimensiones.

2.2.2.1 Base de datos de conocimiento (*knowledge base*)

La primera herramienta, consiste en una búsqueda dentro de la base de datos de conocimiento. Esta base de datos ha sido creada a partir del set de datos *true.csv*, y contiene todos los artículos de este. Los artículos se han almacenado de manera vectorial, a través del *embedding* del título y el contenido de los artículos. Como metadatos se han guardado el título, el tema, y la fecha. El *embedding* se ha realizado con *OpenAIEmbeddings*, librería de *langchain*, con el modelo *text-embedding-ada-002*. Cada artículo es guardado como un documento a la base de datos vectorial, que en este caso se ha creado utilizando *Chroma*, librería también de *langchain*.

El funcionamiento de la herramienta es el siguiente:

1. El agente pasa el título, el contenido, y la fecha del artículo que está examinando.
2. Se buscan los 20 artículos más similares al que se ha pasado de entrada. Los pasos que sigue esta búsqueda son, primero hacer el *embedding* del artículo, lo cual lo convierte en un vector numérico. Segundo, buscar que *embeddings* se encuentran más “cerca” (a través del cálculo de distancia entre vectores). Por último, devuelve los 20 más similares, junto con su puntuación de similitud (distancia).
3. Se filtran los resultados para quedarse solo con artículos con fechas anteriores al de entrada, con el objetivo de evitar filtrar información de futuro.
4. Finalmente, se devuelven los 5 artículos con mayor puntuación que hayan pasado el filtro de fecha, junto con su puntuación de relevancia.

2.2.2.2 Búsqueda en internet de declaraciones puntuales dentro del artículo

Esta herramienta pretende dotar al agente con la capacidad de buscar en internet información sobre hechos discutidos en el artículo. La herramienta funciona de la siguiente manera:

1. El agente pasa el texto de búsqueda y la fecha del artículo
2. Se genera una búsqueda que utiliza los filtros de *Google* para recibir solamente información anterior a la fecha del artículo.
3. A través de una API de *Google*, se realiza la búsqueda de forma programática y se obtienen los 5 primeros resultados.
4. Se aplica un segundo filtro de fecha para evitar filtrar información de fechas posteriores a la del artículo.
5. Se devuelve al agente una lista de resultados que incluyen el título, el link y el *snippet*.

2.2.2.3 Análisis estilístico

Esta herramienta utiliza el modelo *Gemini-1.5-pro* para analizar el estilo en el que está escrito el artículo. En concreto, se utiliza el siguiente *prompt*:

“Analyze this news article for stylistic indicators that might suggest it's fake news.

Focus on:

- 1. Emotional/sensationalist language*
- 2. Bias indicators and partisan language*
- 3. Writing quality and journalistic standards*
- 4. Named entities mentioned and how they're portrayed*
- 5. Any logical fallacies or manipulation tactics*

Format your response as JSON with the following structure:

{{

```
"style_analysis": {{  
    "emotional_language": "Low/Medium/High",  
    "sensationalism": "Low/Medium/High",  
    "writing_quality": "Low/Medium/High"  
}},  
"entities_mentioned": ["List of key people, organizations, places"],  
"manipulation_tactics": ["List of potential manipulation tactics identified"],  
"overall_style_assessment": "Brief explanation of writing style and credibility  
indicators"  
}}
```

Se siguen las buenas prácticas definidas en el apartado 2.2.1. En concreto, se define detalladamente la tarea del modelo, el formato de salida de su análisis, y el objetivo que debe cumplir.

Capítulo 3. ANÁLISIS DE RESULTADOS

En este capítulo se explicará el proceso seguido para extraer los resultados y se detallarán las métricas conseguidas por el modelo.

3.1 METODOLOGÍA DE EXTRACCIÓN DE RESULTADOS

El tiempo de procesamiento de los principales modelos a través de API, pueden llegar a ser muy largos. Por ejemplo, el agente junto con sus dos herramientas llega a una duración de unos 30 segundos para clasificar un artículo. Mientras que 30 segundos puede no ser mucho, si ejecutamos en serie una vez tras otra al agente para clasificar varios artículos, enseguida pasamos a horas de ejecución.

Para lidiar con este problema, se crea un script que habilitará el procesamiento en paralelo de varios artículos a la vez. El *script* se encarga de lo siguiente:

- En primer lugar, cargar los sets de datos que vamos a evaluar (*true.csv* y *fake.csv*).
- Segundo, invocar al agente para conseguir su clasificación a través de una función
- Tercero, procesar artículos en bloques de varios a través de una función que crea un hilo de procesamiento para cada uno. Además, en cada hilo crearemos una nueva instancia del agente para evitar que se contamine la conversación del agente con mensajes de artículos anteriores.
- Por último, para permitir extraer artículos en distintos momentos sin tener que re-procesar artículos para los que ya teníamos predicción, se incluye lógica en el *script* que lee los artículos que ya se han procesado, y se excluyen de la extracción de resultados

Con todo lo mencionado, conseguimos que procesar 600 artículos pase de tardar más de seis horas, a tardar 90 minutos de principio a fin.

3.2 DEFINICIÓN DE MÉTRICAS

Para la tarea de clasificación que se lleva a cabo en este proyecto, se ha escogido medir las siguientes métricas:

- Precisión
- Recall
- F1-score
- Accuracy
- ROC AUC

En este caso, se cuenta con suficientes muestras como para mantener el set de datos de evaluación balanceado entre artículos verdaderos y falsos, por lo que el objetivo es minimizar el número de noticias falsas que pasan el filtro del agente, a la par que se maximiza el número de noticias verdaderas que son clasificadas como tal. Como autor del proyecto, voy a priorizar que no se censuren artículos verdaderos, y que se dejen pasar el menor número de artículos falsos posibles.

3.3 RESULTADOS

Debido al coste de ejecución de los *Large Language Models*, se ha reducido la muestra de evaluación a 397 artículos ingleses y 202 españoles en total, aproximadamente 300 verdaderos y 300 falsos. A continuación, pueden verse los resultados de las principales métricas.

	Actual positive	Actual negative
Predicted positive	197	16
Predicted negative	0	184

Tabla 1. Matriz de confusión del modelo sobre artículos ingleses

	Actual positive	Actual negative
Predicted positive	89	12
Predicted negative	20	81

Tabla 2. Matriz de confusión del modelo sobre artículos españoles

Para los artículos ingleses se consigue:

- Precisión: $197 / (197 + 16) = 92\%$; es decir, el 92% de los artículos clasificados como verdaderos lo son realmente.
- Recall: $197 / (197 + 0) = 100\%$; es decir, el 100% de los artículos que son realmente verdaderos, se clasifican como tal.
- F1-score: $2 * 197 / (2 * 197 + 16 + 0) = 96\%$
- Accuracy: $(197 + 184) / 397 = 96\%$




Ilustración 1. Curva ROC del modelo sobre artículos ingleses

Para los artículos españoles se consigue:

- Precisión: $89 / (89 + 12) = 89\%$
- Recall: $89 / (89 + 20) = 82\%$
- F1-score: $2 * 89 / (2*89 + 12 + 20) = 85\%$




Ilustración 2. Curva ROC del modelo sobre artículos españoles

Teniendo en cuenta todas las métricas presentadas, el agente demuestra ser robusto en sus clasificaciones sobre artículos ingleses, mientras que pierde acierto en los españoles. En la Ilustración 3 se puede apreciar la comparativa entre la exactitud para cada set de datos. La exactitud global sobre el set español es un 12% menor que sobre el inglés. En concreto, destaca menos la disminución en los artículos verdaderos (~12%) ya que un 100% de acierto es un resultado muy elevado. La disminución en los artículos falsos (~10%) si resulta más llamativa. Una posible causa es el método de generación de las noticias falsas del set de datos español, que al no ser noticias reales sirven como *proxy*, pero no representan muestras reales.




Ilustración 3. Comparativa de exactitud entre los sets de datos

A continuación, se muestran dos ejemplos de los artículos que fueron clasificados correctamente en el set de datos inglés:

Ejemplo de artículo verdadero clasificado como verdadero:

Título: “*Senators pledge aggressive Russia probe after meeting with U.S. Justice Department’s No. 2*”

Fecha: 11 de mayo de 2017

Contenido: “*WASHINGTON (Reuters) – The leaders of the Senate Intelligence Committee on Thursday vowed to press ahead with their investigation into alleged Russian meddling in the 2016 U.S. election as aggressively as possible despite turmoil over the firing of the FBI director. The panel’s Republican Chairman Richard Burr and ranking Democrat Mark Warner made the comments to reporters following a meeting with U.S. Deputy Attorney General Rod Rosenstein in the wake of President Donald Trump’s firing of James Comey this week.*”

Respuesta del agente: “*Based on my comprehensive analysis, I can conclude this article is ‘true’. Here’s my reasoning:*

1. Style Analysis:

- *The article follows standard journalistic practices with neutral tone and proper attribution*
- *It's sourced from Reuters, a highly credible news agency*
- *Contains specific, verifiable details about people and events*

2. Historical Context Verification:

- *Related news articles from March and early May 2017 confirm the ongoing Senate Intelligence Committee investigation*
- *The same key figures (Burr and Warner) were consistently involved in the investigation*
- *Previous articles confirm their bipartisan approach to the Russia investigation*

3. Specific Claims Verification:

- *Contemporary sources from May 11, 2017, confirm that Burr and Warner did meet with Rosenstein on that day*
- *The meeting's timing aligns with Comey's firing, which had occurred earlier that week*
- *Multiple independent sources confirm the Senate Intelligence Committee's continued commitment to the investigation*

4. Consistency Factors:

- *The article's details align perfectly with the timeline of events*
- *The statements attributed to the senators are consistent with their previous public positions*
- *The context of Comey's firing and its impact on the investigation is accurately represented*

The article appears to be a straightforward news report of actual events that occurred on May 11, 2017. All key claims are supported by multiple contemporary sources, and the reporting follows standard journalistic practices. There are no red flags for misinformation or fabrication."

Ejemplo de artículo falso clasificado como falso:

Titulo: "George Zimmerman Launches Despicable Attack On Trayvon Martin's Parents"

Fecha: 18 de mayo de 2016

Contenido: "In the wake of his failed efforts to sell the gun he used to murder Trayvon Martin, racist George Zimmerman talked to the Daily Beast and said some pretty horrendous things about the slain teen's parents. They didn't raise their son right,

Zimmerman said. He attacked a complete stranger and attempted to kill him. Zimmerman pursued and initiated an encounter with the unarmed 17-year-old on February 26, 2012 as Martin was crossing through the gated Sanford, Florida community on his way home to his father s house. Despite being told not to pursue Martin, Zimmerman wanted to play cop and did so anyway despite having no reason to do so. He shot and killed Martin with a Kel-Tec PF-9 9mm semi-automatic pistol and claimed self defense and got away with the murder because of Florida s controversial Stand Your Ground law. Zimmerman has been in and out of trouble with the law ever since, and has avoided punishment each time. Further, in a scheme to make money and use the profits to allegedly fight the Black Lives Matter movement, Zimmerman set up an auction seeking buyers for the gun he used to take Trayvon Martin away from his parents forever, parents whom Zimmerman continued to attack during the interview. Sybrina Fulton and Tracy Martin did everything they could to capitalize on her son s death, Zimmerman despicably claimed. She was never a mother figure to him. Tracy Martin couldn t have cared less about their son. He treated him like a dog without a leash. Zimmerman should have stopped talking at that point but he continued to give Martin s parents advice even though he doesn t have any children of his own. Sure, I m sorry for any parent that has lost a child. That being said, I also believe it s their duty to have an internal dialogue to see what they should have done better and what they should have done appropriately. If he succeeds in selling the infamous firearm, Zimmerman claims he will use the money to fight Black Lives Matter, get revenge on the prosecutor who prosecuted him during his murder trial, and fight against Hillary Clinton. The purchaser is guaranteed validity and authenticity of the firearm. A portion of the proceeds will be used to: fight BLM violence against Law Enforcement officers, ensure the demise of Angela Corey s persecution career and Hillary Clinton s anti-firearm rhetoric. It s not the first time Zimmerman has tried to make money off the murder of Trayvon Martin. He once sold a painting of an American flag for \$100,000 on eBay, and conservatives donated thousands of dollars to Zimmerman to help pay his legal expenses. Clearly, this monster has no intention of staying in the shadows of society where he belongs. Featured image via ABC/Wikipedia”

Respuesta del agente: *“Based on my analysis, I conclude this article is 'fake' for the following reasons:*

1. Style Analysis Red Flags:

- The article exhibits extremely emotional and sensationalized language*
- Heavy use of loaded terms like "racist," "monster," and "despicable"*
- Contains opinion-based statements and editorial commentary rather than objective reporting*
- Lacks proper journalistic standards and citations*
- Shows clear bias in its presentation*

2. Content Issues:

- While George Zimmerman did attempt to auction the gun used in the Trayvon Martin shooting in May 2016 (a verifiable fact), the article's presentation of the supposed Daily Beast interview lacks credibility*
- The article makes claims about direct quotes without providing proper context or verification*
- The writing mixes factual events (the auction attempt) with inflammatory commentary and unsubstantiated claims*
- The article ends with an editorial statement calling Zimmerman a "monster," which is inappropriate for a news article*

3. Structure and Sourcing:

- No proper attribution or links to the supposed Daily Beast interview*
- No attempt to get comments from other parties involved*
- Lacks balanced reporting or multiple perspectives*
- No verification of claims made about the auction proceeds or intended uses*

While some elements of the story may be based on real events (the gun auction attempt did happen), this article appears to be a heavily biased, sensationalized piece that fails to meet basic journalistic standards. It's likely either a fake news article or an opinion piece masquerading as news. The emotional language, lack of proper sourcing, and clear bias suggest this is not a legitimate news article but rather a piece designed to provoke emotional responses rather than inform.

A legitimate news article covering these events would:

- Use neutral language*
- Provide proper attribution for quotes*
- Include responses from all parties involved*
- Separate facts from opinion*
- Include proper context and background information*
- Maintain professional journalistic standards*

Therefore, I classify this as 'fake' due to its clear violation of journalistic standards and apparent intent to mislead through emotional manipulation rather than factual reporting."

Cómo se puede observar en ambos ejemplos, el agente triangula su respuesta en base al análisis estilístico de Gemini, a artículos relacionados guardados en la base de conocimiento, y a la búsqueda de hechos concretos en internet. En ambos casos, esa triangulación le lleva a una clasificación correcta. A continuación, se expondrá un ejemplo en el que el agente clasifica el artículo de manera errónea.

Ejemplo de artículo falso clasificado como verdadero:

Título: *"NYC Police Brutally Arrest Postal Worker After Nearly Hitting His Truck (VIDEO)"*

Fecha: 24 de Marzo de 2016

Contenido: *"For Glen Grays, a 27-year-old New York City postal worker March 17 was not a typical day. That's because Grays was arrested after criticizing a police officer s driving. Grays was making deliveries in the neighborhood of Crown Heights in Brooklyn when a car almost hit his mail truck. Grays then did what most drivers would do if they were in the same situation he yelled at the person driving the vehicle for his reckless behavior. What Grays didn t know is that the vehicle was an unmarked police car. It is at this point that four plainclothes police officers get out of the unmarked police car and begin to harass Grays. The incident was recorded by passersby on their cell phones. You can watch the video below. Grays was eventually ticketed with resisting arrest. He was then handcuffed and put in the back of the unmarked police car where he was taken away. It is not a crime for someone to voice outrage after almost being struck by a vehicle It is not a crime to state that you're angry at someone who almost hit you. That is not a crime, Brooklyn Borough President Eric Adams said during a press conference on Tuesday. Adams wants the four police officers involved in the arrest to be investigated. They place handcuffs on an on-duty postal employee delivering the U.S. mail. If they would do that to him in his postal uniform, they would do it to any person of color in that community. When the police arrested Grays, they also left his mail truck unattended possibly violating several federal procedures. Adams thinks that the police should be punished for any violations of federal procedure that may have happened. I believe there were federal violations. Number one, leaving that truck unsecured. Number, two, interrupting the delivery of mail. There are clear NYPD procedures when you are arresting a federal employee. We don t know if even those basic procedures were followed. This the type of police misconduct that leads to the injuries, arrests, and deaths of so many people - people of color in particular - in the United States every year. Featured image from video screenshot"*

Respuesta del agente: *“Based on my investigation, I believe this article is TRUE, but with some sensationalized elements. Here's my reasoning:*

1. Verification of key facts:

- The incident did occur on March 17, 2016, in Crown Heights, Brooklyn*
- The main subject, Glen Grays, was indeed a postal worker who was arrested*
- Brooklyn Borough President Eric Adams did hold a press conference about this incident on March 22, 2016 (as confirmed by the DNA Info article found in the search)*

2. Official response:

- The involvement of Brooklyn Borough President Eric Adams and his public statements about the incident add credibility to the story*
- The press conference and demands for investigation were documented by local news sources*

3. Style Analysis:

- While the article uses emotional language and presents a one-sided narrative, the core facts of the story appear to be accurate*
- The writing style shows some bias and sensationalism, but this doesn't negate the truthfulness of the underlying events*

4. Supporting evidence:

- The incident was recorded on video (mentioned in the article and confirmed by other sources)*
- The specific details about the location, date, and people involved are consistent*
- The quotes from Eric Adams match contemporary news coverage*

5. Context:

- The story fits within the broader context of discussions about police conduct and racial issues in 2016*
- The concerns about federal violations regarding the postal truck being left unattended are legitimate given USPS regulations*

While the article's tone is somewhat sensationalized and it presents a one-sided perspective, the core events described (the arrest of postal worker Glen Grays, the involvement of plainclothes officers, and the subsequent response from Borough President Adams) are verified by contemporary sources. Therefore, I classify this as a TRUE news story, though one that could have benefited from more balanced reporting and less emotional language.”

Al comparar la respuesta del agente en este caso frente al anterior, destaca inmediatamente la diferencia en la seguridad con la que el agente proporciona su respuesta. En el ejemplo correctamente clasificado como verdadero, el agente dice estar completamente seguro de

su respuesta porque el artículo es riguroso, describe hechos de manera objetiva, confía en la fuente (Reuters) y, además, es capaz de verificar todos los hechos descritos en el artículo.

Por otro lado, en el artículo incorrectamente clasificado como verdadero, el agente matiza al comienzo de su respuesta la clasificación, diciendo que se trata de un artículo verdadero, pero en el que se utiliza un tono sensacionalista en varios momentos. En la respuesta confirma que los hechos defendidos en el artículo tuvieron lugar en base a sus búsquedas por internet y a la base de conocimiento.

Sin embargo, en el análisis estilístico, el agente menciona que el artículo está escrito con un tono altamente emocional, y que presenta solo una de las dos caras de la historia.

Finalmente, en el resumen final del agente, éste dice que mientras que los hechos descritos son verdaderos, el artículo podría haber utilizado un tono más neutral y lenguaje menos sensacionalista.

Este ejemplo de falso positivo es representativo de lo que ocurre en los otros demás artículos incorrectamente clasificados. En todos ellos el agente identifica una visión sesgada de los hechos, pero clasifica los artículos como correctos porque comprueba que los hechos descritos verdaderamente ocurrieron.

Por otro lado, en el caso de los artículos españoles, no se encuentra una explicación evidente al factor común de los artículos mal clasificados. A continuación, se muestra un ejemplo de artículo verdadero clasificado como falso:

- Título: La Iglesia sacaría tajada económica de la presencia de Franco en La Almodena
- Fecha: 09-11-2018
- Contenido: “Los visitantes de la cripta pagan un euro voluntario para acceder. La presencia del dictador despertaría el interés de franquistas, turistas y curiosos. Si visitaran la cripta el mismo número de personas que ha acudido en octubre al Valle de los Caídos, la Iglesia se embolsaría más de 500.000 euros al año.”

- Respuesta del agente: *“After analyzing all the available information, I conclude this article is likely FAKE. Here's my reasoning:*
 1. *Style Analysis Red Flags:*
 - *The article shows medium levels of sensationalism*
 - *It lacks proper sourcing and contains unverified claims*
 - *The analysis indicates manipulation tactics including "Appeal to Greed" and lack of transparency*
 - *The writing quality is described as lacking journalistic rigor*
 2. *Content Analysis Issues:*
 - *The article makes specific financial predictions (500,000 euros per year) without providing any concrete evidence or sources*
 - *It assumes direct equivalency between Valle de los Caídos visitors and potential La Almudena visitors, which is speculative*
 - *The voluntary donation of 1 euro is presented as if it would automatically translate to guaranteed income*
 3. *Historical Context (from time-aware search):*
 - *While there was indeed discussion about moving Franco's remains in 2018, the article appears to be speculative about the economic impact.*
 - *No credible sources from the time period confirm the specific visitor numbers or donation amounts claimed*
 - *The comparison with Valle de los Caídos is problematic as it was a different type of site with different historical significance*
 4. *Problematic Elements:*
 - *The article makes assumptions about tourist behavior without supporting evidence*
 - *It presents speculative financial calculations as if they were facts*
 - *The tone suggests a bias in presenting the Church as potentially profiting from the situation*

The article appears to be either entirely fabricated or heavily manipulated news that makes unfounded economic predictions about a sensitive political issue. It lacks journalistic standards such as:

- *Verified sources*
- *Expert opinions*
- *Concrete data to support its claims*
- *Balance in reporting*
- *Proper context*

The combination of sensationalist elements, unverified claims, and speculative financial predictions strongly suggests this is fake news designed to create controversy around a sensitive political issue in Spain.”

A continuación, un ejemplo de artículo falso clasificado como verdadero:

- Título: Debate en el Congreso sobre la reforma educativa
- Fecha: 02-12-2021
- Contenido: “El Congreso de los Diputados ha acogido un intenso debate sobre la reforma educativa propuesta por el Gobierno. Las opiniones están divididas y se espera que este tema genere fuertes discusiones en los próximos meses.”
- Respuesta del agente: “*Based on my analysis, I can conclude this article is 'true' for the following reasons:*

1. Style Analysis:

- *The article uses appropriate journalistic language*
- *There's no sensationalism or emotional manipulation*
- *It mentions specific, verifiable institutions (Congress of Deputies, Government)*
- *The tone is neutral and balanced*

2. Context and Knowledge:

- *The article discusses a real and significant topic in Spanish politics*
- *The mentioned institutions are correct (Congreso de los Diputados is Spain's lower house of parliament)*

- *The timing aligns with known educational reform discussions in Spain during that period*
- *The article acknowledges the controversial nature of the topic without taking sides*

3. Content Credibility:

- *The claims made are modest and realistic*
- *It doesn't make any extraordinary or unlikely assertions*
- *The article acknowledges different viewpoints exist*
- *The prediction about future discussions is reasonable given the topic*

While I encountered some technical issues with the search tools, the article's style, content, and context all align with what would be expected from a legitimate news report about parliamentary proceedings in Spain. The article makes no extraordinary claims and presents the information in a balanced, factual manner typical of genuine news reporting.”

Capítulo 4. CONCLUSIONES

En este capítulo, se analizarán la metodología y los resultados descritos en los capítulos anteriores y se sacarán conclusiones a partir de los mismos. Además, se desarrollará una serie de recomendaciones para futuros estudios.

4.1 CONCLUSIONES SOBRE LA METODOLOGÍA

La presente investigación ha demostrado la viabilidad de un enfoque basado en agentes de IA para la clasificación de artículos periodísticos, aprovechando la sencillez de dos sets de datos previamente depurados y concentrando los esfuerzos en el diseño y evaluación del flujo de trabajo. El reducido esfuerzo de análisis exploratorio de datos permitió destinar recursos al ajuste y comprobación de cada agente, asegurando que Claude-3-5-sonnet, y Gemini-1.5-pro cumplieran con los estándares de calidad esperados. Esta pluralidad de arquitecturas favorece la triangulación de resultados y refuerza la robustez del sistema frente a variaciones en la naturaleza textual de los artículos.

Un pilar fundamental de la metodología ha sido el filtrado estricto por fecha en la base de conocimiento y en las búsquedas en internet: mediante el uso de metadatos temporales se evita cualquier forma de “*data leakage*” y se recrea un entorno realista en el que el agente solo dispone de información histórica. Este diseño garantiza que las predicciones se apoyen únicamente en conocimiento disponible antes de la publicación del texto a clasificar, lo cual es especialmente relevante para aplicaciones en medios de comunicación que demandan objetividad y trazabilidad.

Además, la adopción del procesamiento de artículos en paralelo ha evidenciado la escalabilidad del prototipo, manteniendo latencias bajas y un consumo de recursos ajustado a cargas moderadas.

Asimismo, el enfoque de agentes aporta un valor añadido en términos de explicabilidad: cada decisión de clasificación puede documentarse y justificarse mediante los razonamientos internos de los distintos modelos, lo que facilita su interpretación por parte de editores y auditores. Este grado de transparencia supera al de los modelos ensamblados tradicionales o de *boosting*, que tienden a comportarse como “cajas negras”. En consecuencia, el sistema no solo responde a criterios cuantitativos de precisión, sino que también cumple con estándares de comprensión y confianza, aspectos clave para su adopción en entornos donde la credibilidad informativa es prioritaria.

Además, a través de la metodología descrita se ha comprobado la capacidad de generalización del modelo a sets de datos diferentes, reflejando así con mayor exactitud su capacidad de generalización.

4.2 CONCLUSIONES SOBRE LOS RESULTADOS

Los resultados obtenidos por el flujo de agentes de IA muestran un desempeño sobresaliente en la clasificación de artículos periodísticos sobre el set de datos inglés y notable sobre el set de datos español, con una exactitud global del 96% en el primero y del 84% en el segundo. El sistema además demuestra ser mejor identificar noticias verdaderas a la par que es capaz de filtrar la mayoría de los artículos falsos. El área debajo de la curva ROC también alcanza un valor del 94% en los artículos ingleses y un 82% en los españoles, lo que evidencia la capacidad del agente para discriminar eficazmente entre noticias verdaderas y falsas en el primer caso.

Frente a los enfoques tradicionales basados en transformadores, que alcanzan un *F1-score* del 98 % pero suelen evaluarse “*in-domain*” y pierden hasta un 28% de exactitud al generalizar a nuevos conjuntos de datos, el agente demuestra una mayor robustez ante variaciones del corpus, con una pérdida de exactitud del 12% en un cambio completo de geografía, idioma y estilo de los artículos. En este sentido, se recuerda que el set de datos

español no contiene *fake news* reales, si no generadas artificialmente, por lo que se debería dar más importancia a los resultados sobre el set de datos inglés.

En términos operativos, el agente procesa cada artículo en unos 30s cuando se ejecuta de forma secuencial, y reduce este tiempo a aproximadamente 6s por artículo paralelizando la ejecución con cinco hilos. El coste asociado de aproximadamente 0,02€ por artículo hace viable su despliegue en entornos de producción con volúmenes moderados de noticias. No obstante, convendría complementar estos indicadores cuantitativos con un análisis cualitativo de las explicaciones generadas por los agentes, mediante encuestas o estudios de usabilidad, para validar la percepción de objetividad y confianza por parte de usuarios finales.

En conjunto, los resultados confirman la eficacia del enfoque de agentes de IA: no solo alcanza métricas competitivas en artículos ingleses, sino que añade valor a través de su capacidad explicativa y su resistencia a la variabilidad de los datos.

4.3 RECOMENDACIONES PARA FUTUROS ESTUDIOS

Tras la ejecución del proyecto se han identificado diferentes oportunidades de mejora que podrían realizarse en futuros estudios.

En primer lugar, podría explorarse la posibilidad de incluir distintos agentes a los que se les atribuya una personalidad experta en un tema concreto, de esta forma, un primer agente clasificaría el tema del artículo, y se le pasaría al agente más adecuado para ese tema.

Como se ha mencionado anteriormente en la memoria, atribuirle una personalidad específica a un agente ayuda a contextualizar mejor los *Large Language Models*, lo cual resultará en respuestas más precisas y adecuadas al contexto del artículo. Además, podría incluirse un agente crítico que revisara las clasificaciones y se encargara de mantener la consistencia en la clasificación, ya que cuanto mayor sea el contexto de entrada pasado al

agente clasificador, y más larga sea su respuesta, mayor probabilidad tiene de “perder el hilo” y olvidar matices del comienzo de la información. El agente crítico sería una posible solución para lidiar con este problema, aunque también conllevaría tiempos de ejecución más largos y procesamientos más caros.

En segundo lugar, convendría explorar diversas estrategias de enriquecimiento de las representaciones textuales y de la base de conocimiento. Por un lado, incorporar un ligero *feature engineering* como variables de longitud de documento, densidad léxica, entropía semántica o indicadores de emoción y polaridad, podría mejorar la sensibilidad del agente ante matices narrativos y estilísticos que a menudo se escapan a los modelos puramente basados en LLMs. Por otro lado, ampliar la base de conocimiento con metadatos temáticos, geográficos o de confiabilidad de fuente permitiría contrastar las respuestas de los agentes no solo en función de la fecha, sino también de criterios de autoridad y sesgo potencial. Estas variables auxiliares podrían integrarse como filtros previos o como entradas adicionales al *prompt* de cada agente.

En tercer lugar, podría investigarse la posibilidad de hacer *fine-tuning* sobre varios sets de datos al LLM encargado de clasificar los artículos. Llevar a cabo esta acción es casi seguro que conllevaría un aumento en la exactitud de las clasificaciones, aunque para modelos grandes como los utilizados en este trabajo, conlleva un gran coste de procesamiento y tiempo de entrenamiento. Adicionalmente, se recomienda explorar diferentes variaciones sobre el *prompt* del agente de clasificación de artículos para calibrar mejor los casos en los que predice que un artículo es verdadero erróneamente. Por ejemplo, podría añadirse un matiz en las instrucciones que dijera que en caso de que hubiera una gran falta de objetividad, un claro sesgo, o un lenguaje muy sensacionalista, se clasificará el artículo como falso. Finalmente, una mejora sencilla de implementar pero que conllevaría mayores costes sería utilizar LLMs más avanzados como *Claude Sonnet 3.7* o *4.0*.

Por último, es recomendable profundizar en el análisis de explicabilidad y la aceptación de los usuarios finales. Se sugiere diseñar estudios de usabilidad y percepción con editores y auditores de contenido, evaluando la claridad, coherencia y utilidad de las justificaciones

generadas por los agentes. La recogida de *feedback* cualitativo (mediante encuestas o *focus groups*) y cuantitativo (mediante métricas de satisfacción y tiempo de revisión) permitirá calibrar el balance entre precisión y comprensibilidad. Asimismo, explorar arquitecturas de despliegue más avanzadas, como colas de tareas (RabbitMQ) o soluciones *serverless*, facilitará la adaptación del prototipo a picos de carga elevados, asegurando al mismo tiempo un control de costes y latencias óptimo en entornos de producción periódica.

Capítulo 5. BIBLIOGRAFÍA

- [1] The Hill. (2021, April 14). Google spending \$30M to fight misinformation, fake news. <https://thehill.com/policy/technology/545920-google-spending-30m-to-fight-misinformation-fake-news/>
- [2] HKU Business School. (2023, November 20). Combat misinformation for a stable economy. <https://www.hkubs.hku.hk/research/thought-leadership/hkej-column/combat-misinformation-for-a-stable-economy/>
- [3] Zhou, X., & Zafarani, R. (2020). *A survey of fake news: Fundamental theories, detection methods, and opportunities*. ACM Computing Surveys, 53(5), 1–40. <https://doi.org/10.1145/3395046>
- [4] Sharma, K., et al. (2019). *Combating fake news: A survey on identification and mitigation techniques*. ACM Transactions on Intelligent Systems and Technology, 10(3), 1–42. <https://doi.org/10.1145/3305260>
- [5] Shahi, G. K., Dirkson, A., & Majchrzak, T. A. (2021). *An exploratory study of COVID-19 misinformation on Twitter*. Online Social Networks and Media, 22, 100104. <https://doi.org/10.1016/j.osnem.2021.100104>
- [6] Glazkova, A., et al. (2025). An exploration of features to improve the generalisability of fake news detection models. arXiv:2502.20299. <https://arxiv.org/abs/2502.20299>
- [7] Zhou, J., et al. (2024). Fact-checking based fake news detection: A review. arXiv:2401.01717. <https://arxiv.org/abs/2401.01717>
- [8] Keele University. (2025, January). AI-powered tool developed by Keele scientists can detect fake news with near-perfect accuracy. <https://www.keele.ac.uk/about/news/2025/january/artificial-intelligence/fake-news-detector.php>
- [9] Bhavik Jikarda. (2024). Fake News Detection. <https://www.kaggle.com/datasets/bhavikjikadara/fake-news-detection?resource=download&select=true.csv>
- [10] Javier Otero Vizoso (2024). Spanish Political Fake News. <https://www.kaggle.com/datasets/javieroterovizoso/spanish-political-fake-news>

Parte II Anexo A

PROYECTOS FIN DE MÁSTER CURSO:2024-2025

Parte III Ficha de proyecto fin de máster
Parte IV (RELLENAR CON LETRAS DE IMPRENTA EN ORDENADOR)

Alumno 1º Apellido: Lopez
 2º Apellido: Soto
 Nombre: Ignacio

Teléfono de contacto: +34 620740264
e-mail: 201802973@alu.comillas.edu

Título del Proyecto Fin de Máster: Detección de *fake news* a través de inteligencia artificial

Director (nombre y dos apellidos): Carlos Miguel Vallez Fernández
Teléfono de contacto:
e-mail: cmvallez@icai.comillas.edu

Breve descripción del proyecto (5 o 6 líneas)

En la era digital, las *fake news* amenazan la credibilidad de la información, y este proyecto de fin de máster pretende emplear inteligencia artificial para analizar el contexto y el significado del texto, así como la probabilidad de que sea una *fake news*. Utilizando un dataset diverso de noticias reales y falsas, el sistema se valida rigurosamente para garantizar su precisión. Además, proporciona explicaciones sobre la clasificación de la noticia, garantizando la transparencia del modelo.

El documento final del proyecto será subido al Repositorio Institucional de Comillas con acceso público. El alumno podrá solicitar un nivel restringido de acceso (incluido el "cerrado" o "confidencial") que podrá concederse, excepcionalmente, si está plenamente justificado.

The final report of the Project will be uploaded to the Comillas Institutional Repository with public access. The student will be able to ask for a restricted access (even "closed" or "confidential") which will be exceptionally accepted if it is fully justified.

Aceptación del Director (firma y fecha)

DATOS RELATIVOS AL PROYECTO FIN DE GRADO

Título del Proyecto Fin de Grado: Aplicación de técnicas de aprendizaje automático para evaluar y predecir la actividad geomagnética solar en las comunicaciones

Director/es del Proyecto Fin de Grado: Miguel Ángel Sanz Bobi

Curso Académico en el que se realizó: 2021 / 2021

Universidad (indicarla si no es Comillas):

En el caso de realización en Comillas, indicar especialidad en el Grado: Grado en Ingeniería en Tecnologías de Telecomunicación