

Artículo de Investigación

Implementación de redes neuronales para la clasificación de fuentes informativas en periodismo digital sobre inteligencia artificial

Implementation of neural networks for the classification of information sources in digital journalism about artificial intelligence

Fred Torres-Cruz¹: Universidad Nacional del Altiplano Puno, Perú.

ftorres@unap.edu.pe

Yudi Janeh Yucra-Mamani: Universidad Nacional del Altiplano Puno, Perú.

yudiyucra@unap.edu.pe

Walker Ernesto Aragón-Cruz: Universidad Nacional del Altiplano Puno, Perú.

walkeraragon@unap.edu.pe

Mariana Esther Tovar-Yucra: Universidad Católica de Santa María, Arequipa, Perú

mariana.tovar@ucsm.edu.pe

Fecha de Recepción: 05/06/2024

Fecha de Aceptación: 10/09/2024

Fecha de Publicación: 05/02/2025

Cómo citar el artículo:

Torres-Cruz, F., Yucra-Mamani, Y. J., Aragón-Cruz, W. E. y Tovar-Yucra, M. E. (2025). Clasificación de fuentes informativas de inteligencia artificial en periodismo digital usando redes neuronales [Classification of Artificial Intelligence Information Sources in Digital Journalism Using Neural Networks]. *European Public & Social Innovation Review*, 10, 1-16. <https://doi.org/10.31637/epsir-2025-1436>

¹ Autor Correspondiente: Fred Torres-Cruz. Universidad Nacional del Altiplano Puno (Perú).

Resumen:

Introducción: En la era digital, clasificar fuentes informativas es esencial para mantener la calidad del periodismo, especialmente con inteligencia artificial (IA). Este estudio emplea redes neuronales para esta tarea, evaluando su efectividad y proporcionando interpretaciones claras de los resultados. **Metodología:** Se utilizó un conjunto de datos con 14 características del contenido periodístico, como género, sección de publicación, tipo de fuente y presencia de multimedia. La variable objetivo clasificaba la fuente principal del texto en categorías como experto, político, cultural, religioso, periodístico y otros. El modelo de red neuronal tenía dos capas densas ocultas de 64 neuronas cada una, con activación ReLU. Fue entrenado y evaluado con datos divididos en conjuntos de entrenamiento y prueba. La estandarización de características mejoró el rendimiento del modelo, alcanzando un 46% de precisión en la prueba. **Resultados:** Se aplicaron técnicas como SHAP y LIME para interpretar las predicciones del modelo. SHAP identificó las características más influyentes. LIME ofreció una comprensión detallada de cómo las características específicas afectan las predicciones. **Conclusiones:** Este estudio propone un enfoque innovador para clasificar fuentes informativas en el periodismo digital y destaca la importancia de la interpretabilidad en los modelos de IA.

Palabras clave: Clasificación; fuentes; informativas; inteligencia artificial; periodismo; redes neuronales; SHAP; LIME.

Abstract:

Introduction: In the digital era, classifying information sources is crucial for maintaining the quality of journalism, especially with artificial intelligence (AI). This study employs neural networks for this task, evaluating their effectiveness and providing clear interpretations of the results. **Methodology:** A dataset with 14 characteristics of journalistic content was used, including genre, publication section, source type, and multimedia presence. The target variable classified the primary source of the text into categories such as expert, political, cultural, religious, journalistic, and others. The neural network model had two hidden dense layers with 64 neurons each, using ReLU activation. It was trained and evaluated with data split into training and testing sets. Feature standardization improved the model's performance, achieving 46% accuracy in testing. **Results:** Techniques like SHAP and LIME were applied to interpret the model's predictions. SHAP identified the most influential features. LIME provided a detailed understanding of how specific features affect predictions. **Conclusions:** This study proposes an innovative approach to classifying information sources in digital journalism and highlights the importance of interpretability in AI models.

Keywords: Artificial Intelligence; Classification; Informative Sources; Journalism; LIME Neural Networks; SHAP; Social Media.

1. Introducción

La sociedad está inmersa en una era de expansión de los medios digitales (García et al., 2021), la digitalización ha transformado prácticamente todos los aspectos de la vida moderna, desde la forma en que nos comunicamos hasta cómo trabajamos, aprendemos, nos informamos y nos entretenemos. Plataformas digitales como redes sociales, servicios de *streaming* y aplicaciones de mensajería instantánea son omnipresentes, facilitando la interacción y el intercambio de información a niveles sin precedentes. Vivimos en un contexto donde la digitalización elimina las barreras físicas para el acceso a la información en línea (Zunino, 2022), ello ha permitido que el conocimiento, los datos y las noticias sean accesibles desde cualquier parte del mundo y en cualquier momento.

En este contexto, el periodismo ha entrado en un significativo proceso de digitalización en los sistemas de producción y comunicación de la información, adoptando nuevos modelos de innovación y convergencia multimedia (Sánchez-Gonzales, 2022, citado por Martin-Neira et al., 2024), la tecnología digital ha transformado radicalmente el campo del periodismo, las redacciones tradicionales han evolucionado hacia entornos digitales, cambiando la manera en que se transmite y se recibe la información (Ftah, 2024). El periodismo digital, abarca entonces tanto los medios en internet como las redes móviles (Jiménez & Nicolás-Sans, 2023).

Los contenidos periodísticos se difunden en múltiples formatos, abarcando diversos géneros o moldes (Sabés & Carniel, 2013). Usualmente enmarcados en géneros informativo, interpretativo y de opinión. Empero, las noticias, entrevistas, informes, crónicas, reportajes, editoriales, columnas, entre otros, son denominados también sub-géneros (Francescutti, 2021), que a través de piezas o textos periodísticos se transmiten como historias factuales (López-García & Vizoso, 2021), siendo diversas las formas de narración periodística (Marín, 2004).

Es claro que los medios periodísticos presentan la información desde diversas perspectivas, que incluyen la opinión de un analista político, un reportaje y el testimonio de una persona de la vida cotidiana (Cuevas, 2011). Así la práctica periodística se sustenta en el uso de fuentes (Pérez et al., 2015), ya que proporciona información necesaria para elaborar y verificar las noticias; las fuentes pueden ser personas, documentos, datos o instituciones que ofrecen detalles y contexto sobre un tema específico, el uso adecuado de fuentes informativas es crucial para garantizar credibilidad del medio de comunicación. La fuente informativa es esencial para iniciar cualquier proceso comunicativo, ya que sin ella no habría mensaje, y sin mensaje no se podría establecer la comunicación entre el emisor y el receptor (Prieto, 2018), sin ellas, el flujo de información y el papel del periodismo en la sociedad se verían seriamente comprometidos. Sin fuentes, el periodismo pierde su impacto en la sociedad y se convierte en una simple narración sin novedades (Canavilhas & Giacomelli, 2023), destacamos su importancia crucial al constituirse como base sobre el cual se redacta la pieza periodística (Prieto, 2018).

En el contexto del periodismo digital, la clasificación precisa de las fuentes informativas se ha vuelto fundamental para garantizar la calidad y credibilidad de los contenidos publicados (Pinto & Barbosa, 2024). La evolución tecnológica ha llevado a la integración de herramientas de inteligencia artificial (IA) para optimizar y automatizar diversos procesos en el periodismo, incluyendo la identificación y clasificación de fuentes (Ángel & Franco, 2019). Esta tendencia no solo responde a la necesidad de gestionar grandes volúmenes de información de manera eficiente, sino también a la urgencia de mantener altos estándares de precisión y fiabilidad en un entorno donde la desinformación y las noticias falsas proliferan (Cloarec, 2022).

El uso de redes neuronales en la clasificación de fuentes informativas representa un avance significativo en la automatización del análisis de contenidos periodísticos (Alves & Dos Santos, 2018). Las redes neuronales, inspiradas en el funcionamiento del cerebro humano, son capaces de reconocer patrones complejos en los datos y aprender de ellos para realizar predicciones precisas (Yucra-Mamani et al., 2024), estas se definen como un sistema compuesto por elementos de procesamiento básicos, denominados nodos o neuronas, que están interconectados mediante enlaces que poseen un valor numérico ajustable, conocido como peso (Montaño, 2002), los nodos actúan como unidades de procesamiento individuales que reciben entradas, las procesan mediante funciones de activación y generan salidas. Reconociendo que las redes neuronales son flexibles, tienen la capacidad de aprender de manera autónoma debido a su estructura y funcionamiento (Ponce-Rosas et al., 2023), por lo que su adaptabilidad la convierte en una herramienta poderosa para una amplia gama de aplicaciones en inteligencia artificial, permitiendo que se ajusten y optimicen en función de los

datos y las necesidades específicas, es el caso del ámbito periodístico para la clasificación de fuentes informativas.

Para el periodismo, estas herramientas pueden analizar diversos aspectos del contenido, como el género, la sección de publicación, el tipo de fuente y la presencia de multimedia, para determinar la naturaleza y la fiabilidad de las fuentes utilizadas (Pavlik, 2023). El uso de redes neuronales en el periodismo representa una innovación significativa para el análisis y verificación del contenido, estas herramientas son capaces de realizar análisis complejos y detallados que son esenciales para mantener la integridad y la calidad de la información difundida al público.

A pesar de los avances en el uso de IA en el periodismo, existen desafíos importantes en la interpretación de los modelos de redes neuronales. La interpretabilidad de los modelos es crucial para asegurar que las predicciones sean comprendidas y confiables (Møller & Thylstrup, 2024). Sin interpretabilidad, los periodistas y los editores pueden tener dificultades para confiar plenamente en los resultados proporcionados por las herramientas de IA. Es en este contexto que técnicas como SHAP (SHapley Additive exPlanations) y LIME (Local Interpretable Model-agnostic Explanations) adquieren una relevancia especial, ya que permiten desentrañar cómo y por qué los modelos de IA toman ciertas decisiones.

Este estudio emplea redes neuronales para clasificar fuentes informativas en el periodismo digital y evalúa la efectividad de estas, proporcionando interpretaciones claras de los resultados. Utilizando un conjunto de datos con 14 características del contenido periodístico, se evalúa la precisión del modelo y se aplican técnicas de interpretación como SHAP y LIME para entender mejor las predicciones. El modelo de red neuronal consta de dos capas densas ocultas de 64 neuronas cada una, con activación ReLU, y ha demostrado una precisión del 46% en las pruebas.

Los diferentes textos periodísticos tienen un contenido cuyo abordaje temático fue sobre inteligencia artificial difundido por los medios de comunicación masiva, pues son una de las vías para divulgar (Cuevas, 2011), estos medios corresponden al ámbito internacional, nacional y local, que tras la irrupción de la inteligencia artificial ChatGPT han ocupado primeras planas y son parte de la agenda periodística. ChatGPT fue lanzado el 30 de noviembre de 2022 por OpenAI, una empresa especializada en diálogo en lenguaje natural, que la describe como un prototipo de chatbot de IA basado en un modelo de lenguaje, afinado con técnicas de aprendizaje no supervisado y de refuerzo (OpenAI, 2022).

El objetivo de esta investigación fue la clasificación de fuentes informativas en el periodismo digital, destacando la importancia de la interpretabilidad en los modelos de inteligencia artificial. Al proporcionar una comprensión detallada de cómo y por qué las redes neuronales realizan ciertas predicciones, este estudio busca no solo presentar la precisión de la clasificación, sino también aumentar la confianza en el uso de herramientas de IA en el periodismo.

Tabla 1.
Caracterización de Variables para el Análisis de Contenidos Periodísticos

Variable	Descripción	Categorización
Género del contenido periodístico	Define el formato editorial del contenido analizado, agrupando por características comunes de producción y propósito editorial.	1: Columnas y Editoriales; 2: Reportajes, Crónicas y Entrevistas; 3: Noticias; 4: Otros (incluye géneros no convencionales)
Sección de publicación	Identifica la sección del medio en la que el contenido es publicado, clasificando las secciones por su foco temático principal.	1: Primera plana; 2: Temática política y nacional; 3: Local e internacional; 4: Secciones especializadas (Economía, Ciencia, etc.); 5: Otras
Número de fuentes	Cuenta el total de fuentes utilizadas para la elaboración del contenido, ofreciendo una medida de la amplitud de consulta realizada.	Valor numérico
Tipo de fuente	Agrega las fuentes según su directa contribución y oficialidad al contenido.	Binario: 0 = Ausencia de fuente; 1 = Presencia de al menos un tipo de fuente (Directa, Indirecta, Oficial, Documental, Informal)
Multimedialidad	Evalúa la inclusión de diversos formatos multimedia que acompañan el texto principal.	Binario: 0 = No multimedia; 1 = Presencia de al menos un formato (Texto, Fotografías, Gráficos, Video, Podcast)
Ámbito de la fuente principal	Clasifica la fuente principal del contenido según el sector de pertenencia, proporcionando contexto sobre su autoridad y relevancia.	1: Especializado (Técnico/científico, Religioso); 2: Social (Político, Cultural, Farandulero); 3: Periodístico; 4: Otros; 5: No aplica

Fuente: Elaboración propia (2024)

2. Metodología

La metodología de este estudio se diseñó para evaluar la efectividad de las redes neuronales en la clasificación de fuentes informativas en el periodismo digital, así como para proporcionar una interpretación adecuada utilizando modelos (Fernandes et al., 2023). Se recopiló un conjunto de datos de artículos periodísticos digitales provenientes de diversas plataformas de noticias en línea. La población objetivo incluyó artículos de diversas secciones (noticias, opinión, cultura, política, entre otros) publicados entre enero y junio de 2023. La muestra final, compuesta por 302 artículos, fue seleccionada mediante un muestreo no probabilístico. Se filtraron específicamente los artículos cuya temática se centraba en la Inteligencia Artificial, con el fin de asegurar una representación adecuada de las distintas categorías de fuentes.

Para la inclusión en este estudio, se consideraron artículos publicados en medios digitales reconocidos como "CNN", "Euronews", "El País", "El Comercio Perú", "La República Perú", "TV Perú", "Pachamama Radio Puno", "Sin Fronteras Puno", como se describe en la Tabla 2. Estos artículos cumplieron con ciertos criterios específicos: citar al menos una fuente confiable y pertenecer a una de las secciones temáticas previamente especificadas. Estos requisitos aseguran la credibilidad y relevancia de las fuentes utilizadas. Por otro lado, se excluyeron los artículos que no citan ninguna fuente, las publicaciones duplicadas y aquellos artículos cuya extensión sea inferior a 300 palabras. Estas restricciones fueron implementadas para mantener la integridad y calidad del análisis, eliminando contenidos que pudieran carecer de rigor académico o redundar en la información presentada.

Tabla 2.

Caracterización de Artículos Incluidos para el Estudio

Medio	Nombre	Cantidad
Internacional	CNN	57
	El País	73
	Euronews	69
Nacional	El Comercio Perú	27
	TV Perú	15
	La República Perú	55
Local	Pachamama Radio	3
	Sin Fronteras Puno	3

Fuente: Elaboración propia (2024)

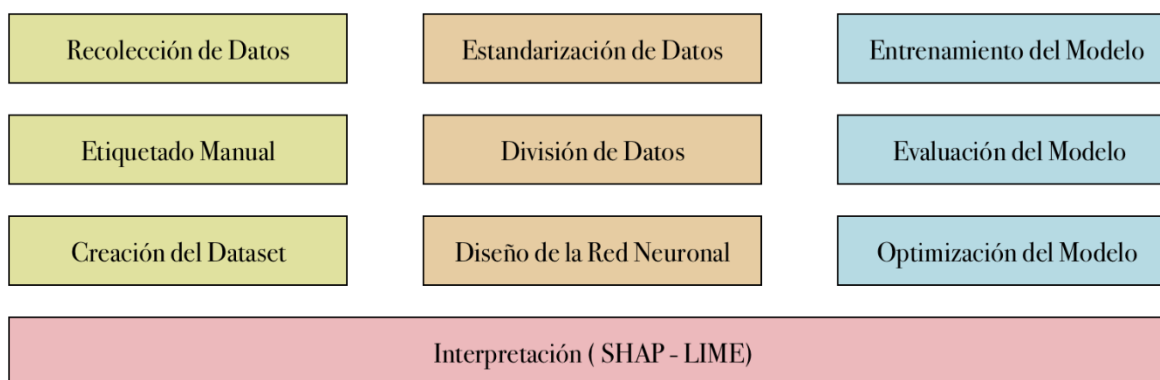
Para la clasificación y construcción del dataset, se llevó a cabo un proceso riguroso de etiquetado manual realizado por especialistas y entendidos en la materia. Estos expertos aplicaron sus conocimientos y experiencia para identificar y categorizar cada dato de manera precisa, asegurando que la información recopilada fuera de alta calidad y relevancia. Este método de etiquetado manual permitió capturar matices y contextos que las técnicas automáticas podrían pasar por alto, garantizando así que el dataset refleje fielmente las complejidades del dominio estudiado (Henestrosa et al., 2023). Este enfoque no solo mejora la exactitud del dataset, sino que también facilita futuras investigaciones y análisis más detallados en el campo.

Para la implementación de la red neuronal, se diseñó una arquitectura con dos capas densas ocultas, cada una compuesta por 64 neuronas. Estas capas utilizan la función de activación ReLU (Rectified Linear Unit) (Abdulmajeed & Fahmy, 2023; Martínez-Vera et al., 2024), que permite al modelo aprender representaciones no lineales complejas al introducir no linealidades en el modelo. La elección de ReLU se basa en su capacidad para mitigar el problema del desvanecimiento del gradiente y mejorar la eficiencia computacional. La capa de salida está equipada con una función de activación softmax, adecuada para tareas de clasificación multiclase. Softmax transforma las salidas del modelo en probabilidades que suman a uno, permitiendo así la interpretación directa de las predicciones en términos de clases. Esta configuración es esencial para problemas donde cada instancia debe ser asignada a una única categoría entre varias posibles.

El modelo fue optimizado utilizando el algoritmo Adam (Adaptive Moment Estimation), conocido por su capacidad para adaptarse dinámicamente a diferentes tasas de aprendizaje a lo largo del entrenamiento (Pinto & Barbosa, 2024). La función de pérdida empleada fue la categórica cruzada, que es adecuada para problemas de clasificación multiclase al medir la discrepancia entre las predicciones del modelo y las etiquetas verdaderas (Pérez-Seijo et al., 2023). Para la división de datos, se empleó una estrategia de división estratificada, asignando el 80% de los datos al conjunto de entrenamiento y el 20% al conjunto de prueba. Esta técnica garantiza que la distribución de las categorías sea consistente en ambos conjuntos, manteniendo la representatividad de los datos. Antes del entrenamiento del modelo, se aplicó una estandarización a las características numéricas utilizando el StandardScaler de la librería Scikit-learn. Este proceso de preprocesamiento ajusta los datos para que todas las características tengan una media de cero y una desviación estándar de uno, mejorando la convergencia del modelo y asegurando que cada característica contribuya equitativamente durante el aprendizaje.

Figura 1.

Proceso de Construcción y Entrenamiento del Modelo de Red Neuronal



Fuente: Elaboración propia (2024)

El modelo fue entrenado durante 50 épocas con un tamaño de lote de 32. La métrica de precisión fue utilizada para evaluar el rendimiento del modelo, y se implementó una técnica de validación cruzada de 5 pliegues durante el entrenamiento. Esta técnica ayudó a prevenir el sobreajuste y asegura la capacidad de generalización del modelo al evaluar su rendimiento en diferentes subconjuntos de datos (Forja-Pena et al., 2024). Para interpretar las predicciones del modelo, se aplicaron dos técnicas de interpretabilidad: SHAP (SHapley Additive exPlanations) y LIME (Local Interpretable Model-agnostic Explanations). SHAP se utilizó para identificar las características más influyentes en las predicciones del modelo, proporcionando una interpretación global de la importancia de cada característica. Esto permitió una comprensión de cómo cada variable contribuye al comportamiento general del modelo. Por otro lado, LIME se aplicó para ofrecer una comprensión detallada de cómo las características específicas afectan las predicciones individuales, facilitando una interpretación local y detallada de cada predicción.

3. Resultados


Para la clasificación de fuentes informativas en periodismo digital, la precisión del modelo evaluado en el conjunto de prueba alcanzó un 46%, con una pérdida de 1.7628. Este resultado indica una capacidad moderada del modelo para clasificar correctamente las fuentes informativas, una tarea crucial en la era digital donde la precisión y la rapidez son esenciales.

Durante el proceso de inferencia, se emplearon 241 muestras de datos de fondo, lo cual puede provocar una ralentización en los tiempos de ejecución. Para mitigar este problema, se recomienda utilizar técnicas de muestreo como `shap.sample (data, K)` o `shap.kmeans (data, K)`, las cuales permiten resumir el fondo en K muestras, optimizando así el rendimiento del modelo. A lo largo de las iteraciones del modelo, se observó una consistencia en los tiempos de procesamiento por paso, manteniéndose en aproximadamente 3 segundos por cada 15605 pasos. Esto refleja una eficiencia constante en el manejo del conjunto de datos. Sin embargo, la precisión actual del modelo puede considerarse insuficiente para aplicaciones críticas en periodismo digital, donde la exactitud de la clasificación de las fuentes informativas es vital para mantener la integridad y la calidad de la información difundida (Espin-Riofrio et al., 2023).

El análisis de los valores de interacción SHAP nos muestra que la sección de publicación (V5) y la fuente indirecta (V9) son las características con mayor impacto en las predicciones del modelo. La dispersión de los valores SHAP para estas características indica que tienen una influencia significativa y variada en la clasificación de las fuentes informativas. Esto sugiere que el contexto en el que se publica un artículo y el uso de fuentes indirectas son factores críticos que el modelo considera al realizar la clasificación. Además de la sección de publicación y la fuente indirecta, el número de fuentes (V6), la fuente directa (V7), la fuente documental (V10), la fuente informal (V11) y la multimedialidad en formato texto (V12) también muestran una notable influencia en las predicciones del modelo. Aunque su dispersión es menor en comparación con V5 y V9, estas características todavía contribuyen de manera significativa como se aprecia en la Figura 2. Esto implica que la diversidad y el tipo de fuentes utilizadas en un artículo, junto con la presencia de contenido textual, son elementos importantes que afectan la decisión del modelo.

Figura 2.

Valores de Interacción SHAP

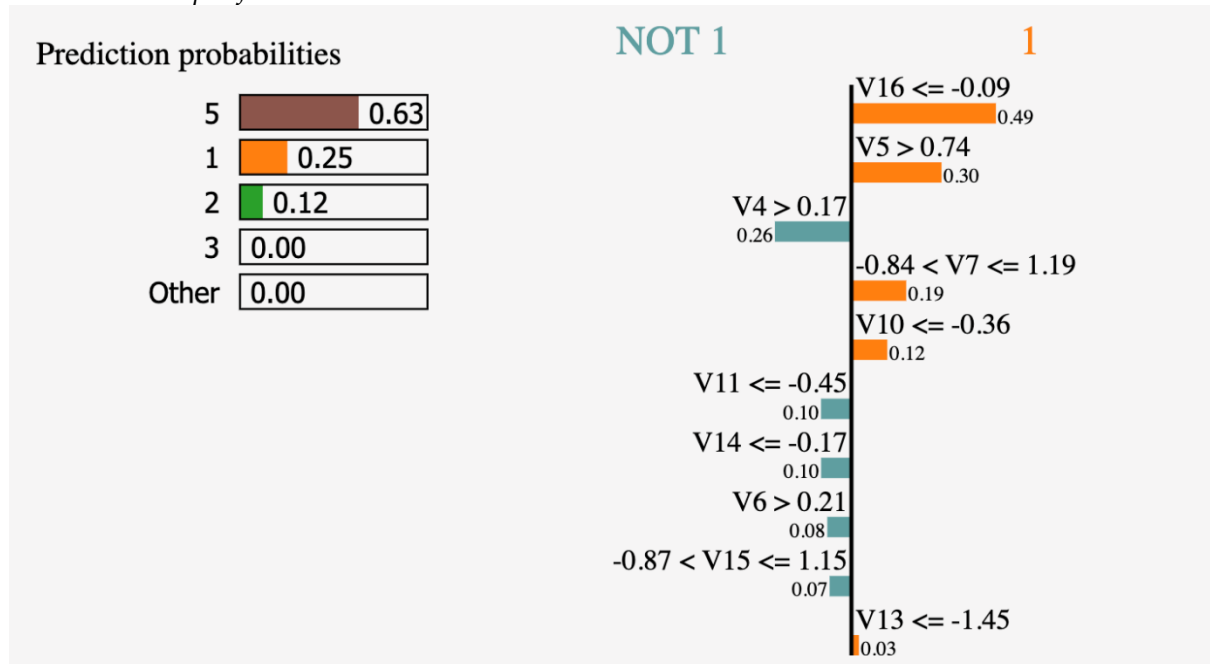


Fuente: Elaboración propia (2024)

La Figura 3 presenta una explicación generada utilizando LIME (Local Interpretable Model-agnostic Explanations) para una predicción específica del modelo. LIME es una técnica que descompone la predicción en contribuciones individuales de las características del modelo, ofreciendo una interpretación local y detallada de cómo se tomó una decisión en particular. Esta capacidad de desglosar las predicciones facilita la comprensión del modelo y ayuda a identificar las características más influyentes en la toma de decisiones.

Figura 3.

Predicciones Específicas del Modelo con LIME



Fuente: Elaboración propia (2024)

En cuanto a las probabilidades de predicción, el modelo muestra una mayor probabilidad del 63% de que la fuente informativa sea de tipo '5' (Noticia principal). Le sigue una probabilidad del 25% para el tipo '1' (Opinión) y un 12% para el tipo '2' (Política). Las categorías '3' (Editorial) y 'Other' no presentan probabilidades significativas. Este desglose de probabilidades ayuda a visualizar la distribución y la confianza del modelo en sus predicciones, lo que es crucial para evaluar su rendimiento y fiabilidad.

Respecto a las características clave, se identifican como las más influyentes V16 (Multimedialidad: Podcast) con un valor ≤ -0.09 y V5 (Sección de publicación) con un valor > 0.74 , ambas aumentando significativamente la probabilidad de que la predicción sea '1' (Opinión). Adicionalmente, V4 (Género: Columna de opinión) con un valor > 0.17 también contribuye positivamente a esta clasificación, aunque en menor medida. Por otro lado, las características V7 (Fuente directa) con valores entre -0.84 y 1.19 , y V10 (Fuente documental) con valores ≤ -0.36 , tienen contribuciones negativas, reduciendo la probabilidad de que la predicción sea '1' (Opinión). La aplicación de LIME en este contexto permite desglosar y visualizar la lógica detrás de las predicciones del modelo, facilitando una mejor comprensión y validación de los resultados obtenidos.

4. Discusión

Los resultados obtenidos del modelo, con una precisión del 46% y una pérdida de 1.7628 en el conjunto de prueba, indican que, si bien el modelo tiene potencial para clasificar fuentes informativas en el ámbito del periodismo digital, todavía hay un margen considerable para mejorar su rendimiento (Abdulmajeed & Fahmy, 2023; Demirci & Sagiroglu, 2022). Esta precisión indica que el modelo es capaz de clasificar correctamente casi la mitad de las fuentes informativas, lo que muestra que el modelo tiene una base para diferenciar entre diversos tipos de fuentes, que es un punto de partida positivo. Asimismo, si bien la pérdida es relativamente alta, sin embargo, no es inusualmente alta para un modelo en sus primeras etapas de desarrollo.

La precisión moderada sugiere que el modelo puede estar subutilizando ciertas características o que el conjunto de datos de entrenamiento no es suficientemente representativo. Además, la pérdida relativamente alta señala la presencia de errores significativos en las predicciones, lo cual es crítico en aplicaciones donde la exactitud es esencial para mantener la integridad de la información periodística (Pérez & Salvador, 2016; Shi et al., 2016). La precisión en el periodismo es crucial para garantizar la credibilidad de las noticias publicadas. Sobre credibilidad, hay consenso en señalar los siguientes cinco criterios de una información en internet:

exactitud: ausencia de errores y posibilidad de confirmar la información en otro soporte; autoridad: información sobre el autor, afiliaciones y reconocimiento de la comunidad; objetividad: identificación de los propósitos del sitio o utilización de un lenguaje persuasivo; actualización periódica: ritmo de oferta de informaciones; cobertura/alcance: profundidad y amplitud de la información ofrecida (Metzger, 2007, citado por Canavilhas & Begoña, 2012, p. 66).

En el contexto del periodismo, estos criterios aseguran que la información no solo sea precisa y fiable, sino también relevante y completa, lo cual es fundamental para mantener la integridad y la confianza del público, por lo que antes de la puesta en ejecución del modelo se debe asegurar que sea lo suficientemente objetivo y veraz para que su aplicación práctica en el ámbito periodístico sea más efectivo y útil en la clasificación de fuentes informativas.

Los hallazgos destacan que la implementación de técnicas de interpretación como SHAP y LIME son fundamentales para abordar estos desafíos (Møller & Thylstrup, 2024; Zhou et al., 2022). Estas herramientas permiten una comprensión detallada de cómo el modelo toma sus decisiones, identificando qué características son más influyentes en las predicciones. Por ejemplo, SHAP proporciona una descomposición aditiva de las contribuciones de cada característica, ofreciendo una visión global del comportamiento del modelo. LIME, por su parte, permite generar explicaciones locales para predicciones específicas, facilitando la detección de posibles sesgos o errores en casos individuales. La utilización de estas técnicas puede ayudar a identificar áreas donde el modelo puede ser mejorado, ya sea mediante el ajuste de hiperparámetros, la incorporación de características adicionales, o la recolección de más datos representativos (Mazhar & Dwivedi, 2024).

Además de la interpretación del modelo, es crucial considerar la eficiencia en el procesamiento de datos. Esto es particularmente problemático en entornos de periodismo digital donde la rapidez en la entrega de información es crucial (Pinto & Barbosa, 2024). En conjunto, estos enfoques no solo mejoran la interpretabilidad y la precisión del modelo, sino que también aseguran que el sistema sea viable para su uso en tiempo real en la industria del periodismo digital.

La mejora continua del modelo es fundamental para potenciar la eficiencia en el procesamiento de datos, la interpretabilidad y la precisión, asegurando así la viabilidad en tiempo real del sistema en la prensa digital. Las mejoras en técnicas de aprendizaje, optimización de recursos, incorporación de modelos explicativos y herramientas de visualización, junto con una validación y actualización constante, son esenciales para mantener la competitividad y la relevancia en un entorno donde la rapidez y la exactitud son cruciales. La integración de estos enfoques no solo mejora la calidad de la información entregada, sino que también garantiza que el sistema sea adaptable, transparente y capaz de soportar el crecimiento continuo de las empresas mediáticas digitales.

5. Conclusión

El modelo de clasificación de fuentes informativas en periodismo digital utilizando redes neuronales muestra un desempeño moderado con una precisión del 46% y una pérdida de 1.7628. Estos resultados subrayan la necesidad de mejoras tanto en la precisión como en la eficiencia del modelo para satisfacer las demandas del entorno periodístico digital. La implementación de técnicas de interpretación como SHAP y LIME es fundamental para comprender mejor las decisiones del modelo y para identificar características clave que pueden ser optimizadas. Además, el uso de técnicas de muestreo para reducir la cantidad de datos de fondo durante la inferencia es crucial para mejorar la velocidad de procesamiento. A través de estos enfoques, es posible no solo aumentar la exactitud del modelo, sino también asegurar su aplicabilidad práctica en escenarios donde la integridad y la rapidez de la información son primordiales.

La implementación de redes neuronales para la clasificación de fuentes informativas en el periodismo digital presenta un gran potencial, aunque actualmente el modelo posee una precisión alrededor del 50%. La investigación resalta la importancia de la combinación entre técnicas automáticas y el etiquetado manual por expertos. Estos especialistas emplearon su conocimiento y experiencia para identificar y categorizar datos de manera rigurosa, capturando matices y contextos que las técnicas automáticas aún necesitan mejorar. La investigación destaca que la combinación de la capacidad tecnológica con la intervención humana no solo mejora la calidad de las noticias, sino que también protege la confianza y la credibilidad del periodismo digital.

Esta investigación demuestra la viabilidad de la automatización de procesos a través de la inteligencia artificial, destacando el uso de redes neuronales. Una versión mejorada de estas tecnologías no solo contribuirá en la reducción de la carga de trabajo manual, sino que también permitirá a los periodistas centrarse en tareas más estratégicas. Además, esta contribución está alineada con los marcos positivos del periodismo hacia la inteligencia artificial, asegurando que la integración tecnológica fortalezca la eficiencia, precisión y calidad de la información.

6. Referencias

- Abdulmajeed, M. y Fahmy, N. (2023). Meta-analysis of AI Research in Journalism: Challenges, Opportunities and Future Research Agenda for Arab Journalism. En N. Editor (Ed.), *Título del libro* (pp. 213-225). https://doi.org/10.1007/978-3-031-17746-0_18
- Ángel, I. T. y Franco, Y. G. (2019). Periódicos digitales españoles e información sobre robótica e inteligencia artificial: Una aproximación a imaginarios y realidades desde una perspectiva de género. *Revista de Comunicación de la SEECI*, 48, 173-189. <https://doi.org/10.15198/seeci.2019.48.173-189>

- Canavilhas, J. y Begoña, I.-N. (2012). Uso y credibilidad de fuentes periodísticas 2.0 en Portugal y España. *El Profesional de La Información*, 1, 63-69. <https://doi.org/10.3145/epi.2012.ene.08>
- Canavilhas, J. y Giacomelli, F. (2023). Inteligencia artificial en el periodismo deportivo: estudio en Brasil y Portugal. *Revista de Comunicación*, 22(1), 53-69. <https://doi.org/10.26441/rc22.1-2023-3005>
- Cloarec, J. (2022). Privacy controls as an information source to reduce data poisoning in artificial intelligence-powered personalization. *Journal of Business Research*, 152, 144-153. <https://doi.org/10.1016/j.jbusres.2022.07.045>
- Cuevas, Y. (2011). Representaciones sociales en la prensa: aportaciones teóricas y metodológicas. *Sinéctica. Revista Electrónica de Educación*, 36, 1-19. http://www.sinectica.iteso.mx/index.php?cur=36&art=36_08
- Demirci, S. y Sagiroglu, S. (2022). TwitterBulletin: An Intelligent and Real-Time Automated News Categorization Tool for Twitter. *Journal of Universal Computer Science*, 28(4), 345-377. <https://doi.org/10.3897/jucs.69377>
- Espin-Riofrio, C., Murillo-Cepeda, V., García-Zambrano, D., Morán, V. M., Gamboa, J. Z. y Montejo-Ráez, A. (julio de 2023). *News Categorisation Based on Pre-Trained Transformer Models*. <https://bit.ly/3WqqBty>
- Fernandes, E., Moro, S. y Cortez, P. (2023). Data Science, Machine learning and big data in Digital Journalism: A survey of state-of-the-art, challenges and opportunities. *Expert Systems with Applications*, 221. <https://doi.org/10.1016/j.eswa.2023.119795>
- Forja-Pena, T., García-Orosa, B. y López-García, X. (2024). The Ethical Revolution: Challenges and Reflections in the Face of the Integration of Artificial Intelligence in Digital Journalism. *Communication and Society*, 37(3 Special Issue), 237-254. <https://doi.org/10.15581/003.37.3.237-254>
- Ftah, K. (2024). Sánchez-Gonzales, H. M. (ed.) (2023). Estrategias del periodismo en la esfera digital: innovación y formación. *Estudios Sobre El Mensaje Periodístico*, 30(1), 275-276. <https://doi.org/10.5209/esmp.92099>
- García, E., Huamán, F. y Palomino, H. W. (2021). Framing periodístico sobre el aborto en el Perú (2015-2019): un análisis comparativo entre la prensa de las regiones Lima metropolitana y Piura. *Revista de Comunicación*, 20(2), 189-206. <https://doi.org/10.26441/RC20.2-2021-A10>
- Jiménez, C. y Nicolás-Sans, R. (2023). Ethical journalism vs digital journalism. *VISUAL Review. International Visual Culture Review*, 10, 1-10. <https://doi.org/10.37467/revvisual.v10.4623>
- Lermann Henestrosa, A., Greving, H. y Kimmerle, J. (2023). Automated journalism: The effects of AI authorship and evaluative information on the perception of a science journalism article. *Computers in Human Behavior*, 138. <https://doi.org/10.1016/j.chb.2022.107445>

- López-García, X. y Vizoso, Á. (2021). High-tech journalism: a sign of the digital era of the third millennium. *Profesional de La Informacion*, 30(3), 1-12. <https://doi.org/10.3145/epi.2021.may.01>
- Marín, C. (2004). *Manual de Periodismo*. Grijalbo.
- Martin-Neira, J. I., Trillo-Domínguez, M. y Olvera-Lobo, M. D. (2024). El periodismo científico en el actual ecosistema digital: retos y alertas desde la perspectiva de los profesionales chilenos. *Revista Mediterranea de Comunicacion*, 15(1), 39-58. <https://doi.org/10.14198/MEDCOM.25346>
- Martínez-Vera, E., Rosado-Muñoz, A. y Bañuelos-Sánchez, P. (2024). Estimación del estado de carga de una batería de litio con redes neuronales y validación con FPGA-en-lazo. *Revista Iberoamericana de Automática e Informática Industrial*, 21(3), 243-251. <https://doi.org/10.4995/riai.2024.20718>
- Mazhar, K. y Dwivedi, P. (2024). Decoding the black box: LIME-assisted understanding of Convolutional Neural Network (CNN) in classification of social media tweets. *Social Network Analysis and Mining*, 14(1). <https://doi.org/10.1007/s13278-024-01297-8>
- Melo Alves, F. M. y Dos Santos, B. A. (2018). Traditional and digital information sources and resources: Some international classifications. *Biblios*, 72, 35-50. <https://doi.org/10.5195/biblios.2018.459>
- Møller, H. J. y Thylstrup, N. B. (2024). The Algorithmic Gut Feeling–Articulating Journalistic Doxa and Emerging Epistemic Frictions in AI-Driven Data Work. *Digital Journalism*. <https://doi.org/10.1080/21670811.2024.2319641>
- Montaño, J. J. (2002). *Redes neuronales artificiales aplicadas al análisis de datos* [Tesis de doctorado, Universidad de les Illes Balears]. <http://hdl.handle.net/10803/9441>
- OpenAI. (2022). Online ChatGPT: optimizing language models for dialogue. *CloudHQ Blog*. <https://blog.cloudhq.net/openais-chatgpt-optimizing-language-models-for-dialogue/#what-is-chatgpt>
- Pavlik, J. V. (2023). Collaborating With ChatGPT: Considering the Implications of Generative Artificial Intelligence for Journalism and Media Education. *Journalism & Mass Communication Educator*, 78(1), 84-93. <https://doi.org/10.1177/10776958221149577>
- Pérez-Seijo, S., Barbosa, S. y Vicente, P. N. (2023). Artificial Intelligence in Journalism: Case Study of the Spanish, Portuguese and Brazilian News Media Systems. En *Studies in Big Data* (Vol. 140, pp. 261-274). https://doi.org/10.1007/978-3-031-43926-1_18
- Pérez, C., Gutiérrez Rubio, D., Sánchez González, T. y Zurbano Berenguer, B. (2015). The use of journalistic sources on politics, economy and culture sections in spanish journalism proximity. *Estudios Sobre El Mensaje Periodístico*, 21, 101-117. https://doi.org/10.5209/rev_ESMP.2015.v21.50661
- Pérez, S. y Salvador, R. (2016). *Diagnóstico, manejo y evolución materno fetal de embarazadas y puerperas que conviven con VIH, atendidas en el Hospital Alemán Nicaragüense, período comprendido entre enero de 2014 a diciembre de 2015*.

- Pinto, M. C. y Barbosa, S. O. (2024). Artificial Intelligence (AI) in Brazilian Digital Journalism: Historical Context and Innovative Processes. *Journalism and Media*, 5(1), 325-341. <https://doi.org/10.3390/journalmedia5010022>
- Ponce-Rosas, E. R., Dávila-Mendoza, R., Jiménez-Galván, I., Fernández-Ortega, M. A., Ortiz-Montalvo, A. y Fajardo-Ortiz, G. (2023). Aplicación de redes neuronales artificiales en el liderazgo asignado y el éxito académico en egresados de medicina. *Cirugía y Cirujanos*, 91(4), 550-560. <https://doi.org/10.24875/CIRU.22000318>
- Prieto, A. (2018). El empleo de las fuentes informativas en el tratamiento de la ley de extranjería por la prensa española. *Estudios Sobre El Mensaje Periodístico*, 24(1), 323-340. <https://doi.org/10.5209/ESMP.59953>
- Sabés, F. y Carniel Bugs, R. (2013). Tratamiento de los géneros periodísticos en la información de la prensa euromediterránea. *Historia y Comunicación Social*, 18, 15-32. https://doi.org/10.5209/rev_HICS.2013.v18.43945
- Shi, B., Ifrim, G. y Hurley, N. (2016). *Learning-to-rank for real-time high-precision hashtag recommendation for streaming news*. En Proceedings of the 25th International Conference on World Wide Web (pp. 1191-1202). International World Wide Web Conferences Steering Committee. <https://doi.org/10.1145/2872427.2882982>
- Yucra-Mamani, Y. J., Torres-Cruz, F. y Aragón-Cruz, W. E. (2024). Percepción visual en redes sociales de fotografías reales y sintetizadas mediante inteligencia artificial. *VISUAL REVIEW. International Visual Culture Review / Revista Internacional de Cultura Visual*, 16(4). <https://doi.org/10.62161/revvisual.v16.5302>
- Zhou, X., Li, Y., Sun, Y., Su, Y., Li, Y., Yi, Y. y Liu, Y. (2022). Research on Dynamic Monitoring of Grain Filling Process of Winter Wheat from Time-Series Planet Imageries. *Agronomy*, 12(10). <https://doi.org/10.3390/agronomy12102451>
- Zunino, E. (2022). Brechas y concentración de la información: un estudio sobre agendas, encuadres y consumos de noticias sobre vacunas en el marco del Covid-19 en la Argentina. *Revista de Comunicación*, 21(1), 469-495. <https://doi.org/10.26441/rc21.1-2022-a24>

CONTRIBUCIONES DE AUTORES/AS, FINANCIACIÓN Y AGRADECIMIENTOS

Contribuciones de los/as autores/as:

Conceptualización: Torres-Cruz, Fred; Yucra-Mamani, Yudi Janeh. **Software:** Torres-Cruz, Fred; **Validación:** Tovar Yucra, Mariana Esther, Aragón-Cruz, Walker Ernesto. **Análisis formal:** Torres-Cruz, Fred. **Curación de datos:** Yucra-Mamani, Yudi Janeh, Aragón-Cruz, Walker Ernesto. **Redacción - Preparación del borrador original:** Aragón-Cruz, Walker Ernesto, Yucra-Mamani, Yudi Janeh, Torres-Cruz, Fred; **Redacción - Revisión y Edición:** Tovar Yucra, Mariana Esther, Aragón-Cruz, Walker Ernesto. **Visualización:** Yucra-Mamani, Yudi Janeh; **Supervisión:** Torres-Cruz, Fred. **Todos los/as autores/as han leído y aceptado la versión publicada del manuscrito:** Torres-Cruz, Fred; Yucra-Mamani, Yudi Janeh; Aragón-Cruz, Walker Ernesto; Tovar Yucra, Mariana Esther.

Financiación: Esta investigación recibió o no financiamiento externo.

Conflicto de intereses: Esta investigación no registra conflicto de intereses.

AUTORES:

Fred Torres-Cruz:

Universidad Nacional del Altiplano Puno.

Ingeniero Estadístico e Informático con Maestría en Ingeniería de Sistemas y Estudiante del Doctorado en Ciencias de la Computación, en la Universidad Nacional del Altiplano, miembro del Instituto de Investigación en Ciencia de la Computación. Actualmente se desempeña como docente en la Escuela Profesional de Ingeniería Estadística e Informática de la UNAP, desarrolla cátedra en pregrado y posgrado en diferentes universidades. Investigador RENACYT.

ftorres@unap.edu.pe

Índice H: 4

Orcid ID: <https://orcid.org/0000-0003-0834-6834>

Scopus ID: <https://www.scopus.com/authid/detail.uri?authorId=57214066496>

Google Scholar: <https://scholar.google.es/citations?user=nBpjb7oAAAAJ>

ResearchGate: <https://www.researchgate.net/profile/Fred-Torres-Cruz>

Yudi Janeh Yucra Mamani:

Universidad Nacional del Altiplano Puno.

Licenciada en Ciencias de la Comunicación Social por la Universidad Nacional del Altiplano Puno (UNAP), Magister Scientiae en Ciencias Sociales, mención Comunicación para el Desarrollo, Doctoris Scientiae en Ciencias Sociales. Docente principal de la Escuela Profesional de Ciencias de la Comunicación Social de la UNAP, imparte cátedra en pregrado y posgrado en la UNAP. Investigadora RENACYT. Directora del Instituto de Investigación Social y Empresarial (IDISEM). Con experiencia profesional en Periodismo y Relaciones Públicas.

yudiyucra@unap.edu.pe

Índice H: 1

Orcid ID: <https://orcid.org/0000-0002-9483-7949>

Scopus ID: <https://www.scopus.com/authid/detail.uri?authorId=57998118600>

Google Scholar:

https://scholar.google.es/scholar?hl=es&as_sdt=0%2C5&q=yudi+yucra+mamani&oq=yudi+yucra

ResearchGate: <https://www.researchgate.net/profile/Yudi-Janeh-Yucra-Mamani>

Walker Ernesto Aragón Cruz:

Universidad Nacional del Altiplano Puno.

Licenciado en Ciencias de la Comunicación Social por la Universidad Nacional del Altiplano Puno (UNAP), posee grado académico de Maestro en Ciencias, con mención en Comunicación y Doctoris Scientiae en Ciencias Sociales. Actualmente se desempeña como docente auxiliar en la Escuela Profesional de Ciencias de la Comunicación Social de la UNAP, desarrolla cátedra en pregrado y posgrado en la UNAP. Investigador RENACYT. Y miembro del directorio del Instituto de Investigación Social y Empresarial (IDISEM). Cuenta con experiencia profesional en Comunicación para el desarrollo y producción en medios.

walkeraragon@unap.edu.pe

Índice H: 1

Orcid ID: <https://orcid.org/0000-0002-0139-2961>

Google Scholar:

https://scholar.google.es/scholar?hl=es&as_sdt=0%2C5&q=WALKER+ERNESTO+ARAG%3%93N+CRUZ&btnG=

Mariana Esther Tovar Yucra:

Universidad Católica de Santa María.

Estudiante de Psicología en la Universidad Católica de Santa María (Arequipa). Ha participado como ponente en congresos científicos internacionales y nacionales, tiene publicaciones sobre comunicación, género y transmedia. Realizó prácticas en instituciones educativas públicas y privadas de Arequipa. En el ámbito organizacional, se centró en recursos humanos y gestión de personal.

mariana.tovar@ucsm.edu.pe

Orcid ID: <https://orcid.org/0009-0002-7522-3826>

Google Scholar: https://scholar.google.com/citations?user=Ois_JwEAAAAJ&hl=es

Academia.edu: <https://ucsm.academia.edu/MarianaEstherTovarYucra>