



Facultad de Ciencias Económicas y Empresariales

Descifrando la Percepción Pública sobre ChatGPT: Un Estudio a partir del Análisis Automático de Publicaciones de X

Autor: Elena Suárez García

Director: Jenny Alexandra Cifuentes Quintero

MADRID | Abril 2024

Resumen

El creciente reconocimiento de la *Inteligencia Artificial Generativa* se debe a su capacidad para innovar en la creación de contenido, abarcando desde textos hasta imágenes, lo que extiende notablemente las capacidades creativas humanas. Esta tecnología disruptiva está generando transformaciones en diversas industrias, así como en las interacciones y relaciones entre individuos, generando tanto expectativas como preocupaciones que requieren de constante evaluación. En este contexto, las redes sociales han emergido como herramientas clave para capturar y analizar la percepción pública. Estas plataformas proporcionan acceso directo a una amplia variedad de opiniones a nivel global, caracterizándose por su capacidad de difusión instantánea y la autenticidad con la que los usuarios expresan sus puntos de vista. Esto facilita la recopilación de datos relevantes sobre las actitudes de los ciudadanos hacia temas de actualidad tecnológica.

El presente estudio se enfoca en la recopilación de información relevante sobre la percepción pública de los primeros usuarios de *ChatGPT*, reconocida como la más reciente tecnología disruptiva. Siguiendo la metodología de investigaciones similares, se analizan publicaciones de la red social *X*, anteriormente conocida como *Twitter*, utilizando técnicas avanzadas de *Procesamiento de Lenguaje Natural*. Específicamente, *Latent Dirichlet Allocation* para el modelado de tópicos y *Valence Aware Dictionary and sEntiment Reasoner* para el análisis de sentimientos. El modelado de tópicos muestra cinco áreas principales de discusión en línea: Grandes Inversiones y Desarrollos en el Campo Tecnológico, Interés y Perspectivas Futuras en la *Inteligencia Artificial*, Innovación en el Procesamiento de Lenguaje, Utilización Práctica de Modelos de Lenguaje, Generación de Contenido y Reflexión Ética. Estas temáticas reflejan el interés en los avances tecnológicos y sus posibles utilidades prácticas, así como las preocupaciones éticas. El análisis de sentimientos muestra una percepción mayormente positiva hacia *ChatGPT*, con picos de interés coincidiendo con eventos tecnológicos relevantes. Sin embargo, se observan sentimientos más neutros en áreas relacionadas con inversiones y ética, reflejando las preocupaciones sociales existentes. Este enfoque metodológico ofrece una comprensión detallada del entorno en el que *ChatGPT* funciona. Además, los resultados obtenidos en este estudio posibilitan la formulación de estrategias de desarrollo orientadas a satisfacer las necesidades en evolución de su audiencia.

Palabras Clave: *ChatGPT*, *X*, percepción, modelado de tópicos, análisis de sentimiento.

Abstract

The growing recognition of the *Generative Artificial Intelligence* stems from its capacity to innovate in content creation, spanning from texts to images, significantly extending human creative capabilities. This disruptive technology is driving transformations across various industries, as well as in interactions and relationships among individuals, generating both expectations and concerns that require ongoing evaluation. In this context, social networks have emerged as key tools for capturing and analyzing public perception. These platforms provide direct access to a wide range of opinions globally, characterized by their ability for instant dissemination and the authenticity with which users express their viewpoints. This facilitates the collection of relevant data regarding citizens' attitudes toward current technological issues.

This study focuses on gathering relevant information about the public perception of early users of *ChatGPT*, recognized as the latest disruptive technology. Following the methodology of similar research, posts from the social network *X*, formerly known as Twitter, are analyzed using advanced Natural Language Processing techniques. Specifically, *Latent Dirichlet Allocation* for topic modeling and *Valence Aware Dictionary and sEntiment Reasoner* for sentiment analysis. The topic modeling reveals five main areas of online discussion: Major Investments and Developments in the Technological Field, Interest and Future Perspectives in *Artificial Intelligence*, Innovation in Language Processing, Practical Use of Language Models, Content Generation, and Ethical Reflection. These themes reflect interest in technological advancements and their potential practical utilities, as well as ethical concerns. Sentiment analysis shows a mostly positive perception towards *ChatGPT*, with peaks of interest aligning with relevant technological events. However, more neutral sentiments are observed in areas related to investments and ethics, reflecting existing social concerns. This methodological approach offers a detailed understanding of the environment in which *ChatGPT* operates. Furthermore, the results obtained in this study enable the formulation of development strategies aimed at meeting the evolving needs of its audience.

Keywords: *ChatGPT*, *X*, perception, topic modeling, sentiment analysis.

Índice general

1. Introducción	1
1.1. Motivación	1
1.2. Objetivos	4
1.2.1. Objetivo General	4
1.2.2. Objetivos Específicos	5
1.3. Estructura del documento	5
2. Percepción Pública sobre Nuevas Tecnologías a través de RRSS: Revisión de la Literatura	6
3. Metodología de Análisis de Datos	15
3.1. Adquisición y Preparación de los Datos	15
3.2. Pre-procesamiento de los Datos	17
3.3. Exploración de <i>N-Gramas</i>	19
3.4. Modelado de Tópicos	21
3.5. Análisis de Sentimientos	26
4. Resultados	29
4.1. Adquisición y Preparación de los Datos	29
4.2. Pre-procesamiento de los Datos	37
4.3. Análisis de <i>N-Gramas</i>	38
4.3.1. Análisis de Unigramas	39
4.3.2. Análisis de Bigramas	39
4.3.3. Análisis de Trigramas	40
4.4. Modelado de Tópicos	42
4.5. Análisis de Sentimientos	48
5. Conclusiones	56
Bibliografía	61

Índice de figuras

1.1. Comparativa del crecimiento de usuarios en Servicios Online. Fuente de datos: (Statista, 2023). Elaboración propia	2
1.2. Búsqueda del término “ChatGPT” en <i>Google</i> . Fuente de datos: <i>Google Trends</i> (Google, 2023). Elaboración propia	2
1.3. Evolución del número de usuarios de <i>ChatGPT</i> . Fuente de datos: (Nerdynav, 2024). Elaboración propia	4
3.1. Fases de la Metodología de Análisis. Elaboración propia	16
3.2. Fases en el Pre-procesamiento de datos. Elaboración propia	18
3.3. Representación de los valores de <i>TF-IDF</i> según los valores tomados por sus métricas. Elaboración propia	21
3.4. Representación de la lógica de clusterización detrás de la técnica <i>LDA</i> . Elaboración propia	23
3.5. Diagrama descriptivo de la técnica <i>LDA</i> . Elaboración propia	24
4.1. Análisis Temporal: Frecuencia Diaria de Publicaciones de <i>X</i> . Elaboración propia	32
4.2. Análisis Temporal: Frecuencia Semanal de Publicaciones de <i>X</i> . Elaboración propia	32
4.3. Análisis Lingüístico: Principales Idiomas Identificados en las Publicaciones de <i>X</i> . Elaboración propia	34
4.4. Análisis de Emoticonos: Principales <i>Emojis</i> Identificados en las Publicaciones de <i>X</i> . Elaboración propia	35
4.5. Análisis de los Principales <i>hashtags</i> Presentes en las Publicaciones de <i>X</i> . Elaboración propia	36
4.6. Nube de Palabras basada en la Frecuencia de Términos en el Corpus. Elaboración propia	38
4.7. 30 Unigramas de Mayor Relevancia en el Corpus. Elaboración propia	40
4.8. 30 Bigramas de Mayor Relevancia en el Corpus. Elaboración propia	41
4.9. 30 Trigramas de Mayor Relevancia en el Corpus. Elaboración propia	42
4.10. Índice de coherencia por número de tópicos. Elaboración propia	43

4.11. Mapa de Distancia Intertópica para $k = 5$. Elaboración propia	44
4.12. Distribución de publicaciones por Tópico. Elaboración propia	48
4.13. Distribución de la Puntuación de las Publicaciones. Elaboración propia	49
4.14. Puntuación Compuesta del Corpus. Elaboración propia	50
4.15. Puntuación Compuesta por Tópico. Elaboración propia	52
4.16. Dispersión de Sentimiento por Tópico. Elaboración propia	53
4.17. Puntuación Compuesta por Día de la Semana. Elaboración propia	54

Índice de tablas

2.1. Resumen de los estudios sobre el análisis de la percepción ciudadana al usar diversas tecnologías disruptivas.	13
4.1. Variable contenidas en el dataset seleccionado	30
4.2. Variable contenidas en el dataset seleccionado	30
4.3. Distribución de Longitudes de Publicaciones	33
4.4. Resumen de los términos más relevantes encontrados en los 5 tópicos modelados	47
4.5. Resumen Estadístico del Sentimiento por Tópicos	53

Acrónimos

<i>API</i>	Application Program Interface
<i>AWS</i>	Amazon Web Services
<i>BD</i>	Big Data
<i>BERT</i>	Bidirectional Encoder Representations from Transformers
<i>BoW</i>	Bag of Words
<i>ChatGPT</i>	Chat Generative Pre-trained Transformer
<i>CRISPR-Cas9</i>	Clustered Regularly Interspaced Short Palindromic Repeats <i>Cas9</i>
<i>EmoLex</i>	National Research Council Canada Word-Emotion Association Lexicon
<i>GA</i>	Google Assistant
<i>IA</i>	Inteligencia Artificial
<i>IAG</i>	Inteligencia Artificial Generativa
<i>IDF</i>	Inverse Document Frequency
<i>IS</i>	Ingeniería del Software
<i>LDA</i>	Latent Dirichlet Allocation
<i>LLM</i>	Large Language Models
<i>LSA</i>	Latent Semantic Analysis
<i>MALLET</i>	Machine Learning for Language Toolkit
<i>ML</i>	Machine Learning
<i>NB</i>	Naïve Bayes
<i>NFT</i>	Activos Digitales no Fungibles
<i>NRC</i>	National Research Council
<i>NPL</i>	Procesamiento del Lenguaje Natural
<i>RA</i>	Realidad Aumentada
<i>RRSS</i>	Redes Sociales
<i>RSC</i>	Responsabilidad Social Corporativa
<i>RV</i>	Realidad Virtual
<i>SVM</i>	Support Vector Machine
<i>TF</i>	Term Frequency
<i>TF-IDF</i>	Term Frequency - Inverse Document Frequency
<i>TFG</i>	Trabajo de Fin de Grado

VADER Valence Aware Dictionary for Sentiment Reasoning

Capítulo 1

Introducción

1.1. Motivación

En la era actual de interconexión digital, comprender cómo la sociedad percibe y se involucra con la *Inteligencia Artificial (IA)* ha pasado al plano principal de los estudios. Entre los numerosos avances que ha supuesto el surgimiento de la *IA*, destacan los *Large Language Models (LLM)*, entre los cuales se encuadra *ChatGPT (Chat Generative Pre-trained Transformer)*. Este avanzado modelo de lenguaje preentrenado ha capturado la atención ciudadana al ofrecer diálogos casi humanos y demostrar habilidades en otras actividades relacionadas con el lenguaje, caracterizadas por una elevada precisión (Kasneci et al., 2023). *ChatGPT* se presenta como un ejemplo emblemático de los progresos experimentados tanto en la *IA* como en el *Aprendizaje Automático*, conocido también como *Machine Learning (ML)*. El dominio de esta tecnología se disparó a partir de su nacimiento en noviembre de 2022, alcanzando un millón de usuarios en tan solo 5 días y los cien millones en 60 días (De Angelis et al., 2023), estadísticas que superaron de manera inmediata la evolución de cualquier otro servicio en línea hasta la fecha (Ver Figura 1.1).

Esta tecnología disruptiva ha generado un impacto significativo en diversos aspectos de la vida cotidiana, aumentando el interés de la sociedad por afrontar los nuevos desafíos que plantea (Correa, 2023). Esta observación se confirma al analizar la tendencia de búsqueda del término “ChatGPT” a nivel internacional en *Google*. La Figura 1.2 revela cómo, tras su lanzamiento el 30 de noviembre de 2022, *ChatGPT* experimentó un aumento explosivo de popularidad, incremento que se mantuvo constante en los meses siguientes. Sin embargo y a pesar de este fenómeno inicial, se observa una disminución en el interés público por la plataforma a partir de mayo de 2023.¹

Una de las características clave que ha propiciado el rápido crecimiento de esta tecno-

¹Los valores proporcionados por *Google Trends* están estandarizados. Los datos representan el interés de búsqueda en relación con el valor máximo de la lista correspondiente a la región y al período especificado. Bajo esta métrica, el valor 100 indica la máxima popularidad del término, 50 implica la mitad de popularidad, y 0 significa que no hubo suficientes datos disponibles para ese término en el período especificado.

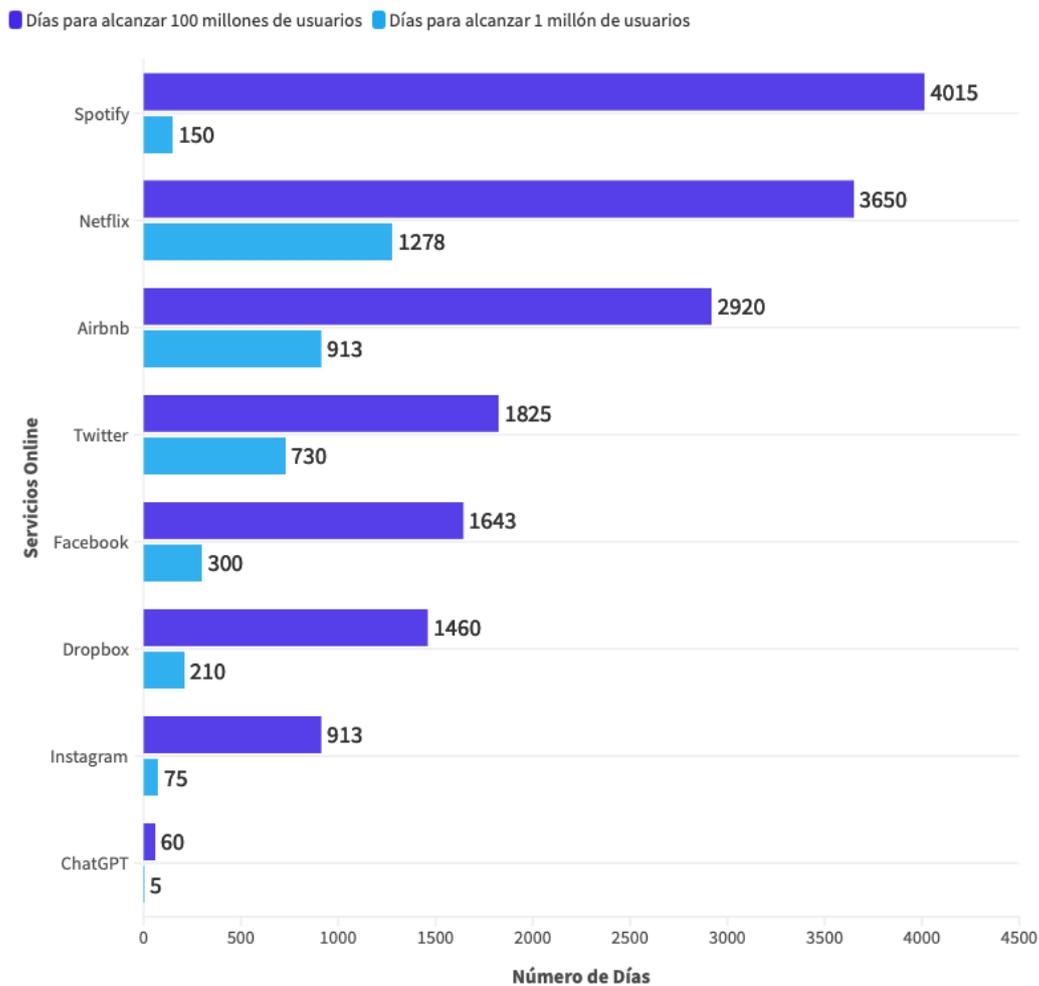


Figura 1.1: Comparativa del crecimiento de usuarios en Servicios Online. Fuente de datos: (Statista, 2023). Elaboración propia

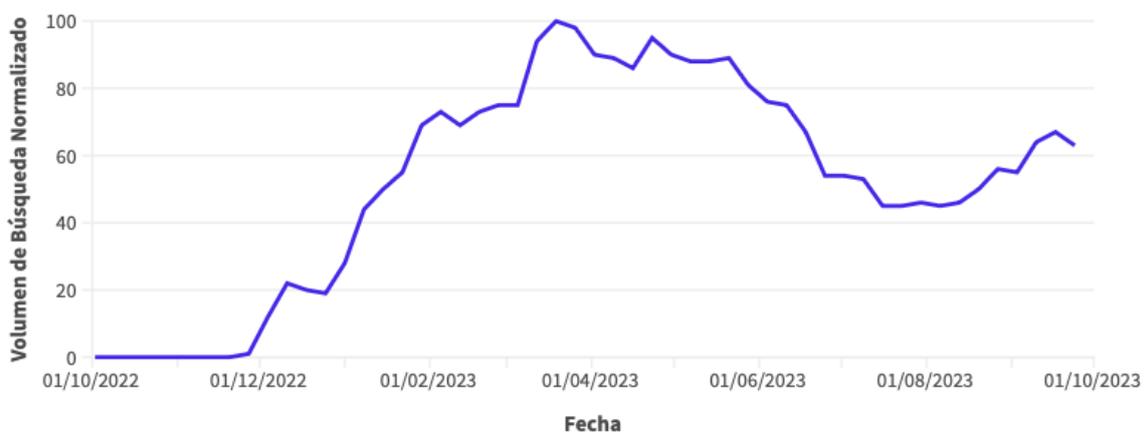


Figura 1.2: Búsqueda del término “ChatGPT” en *Google*. Fuente de datos: *Google Trends* (Google, 2023). Elaboración propia

logía es su amplia eficacia en diversas áreas. *ChatGPT* demuestra su funcionalidad a través de actividades como la creación de contenido, traducción, redacción de ensayos e incluso programación informática, convirtiéndose en una herramienta versátil y polifacética (Sohail et al., 2023). Su aplicabilidad abarca numerosas industrias que ya están adaptándose a los cambios impulsados por el acelerado desarrollo de la *IA*. En el ámbito del periodismo, por ejemplo, se prevé que esta tecnología transformará la automatización de contenidos y la forma en que accedemos a la información (Gutiérrez-Caneda, Vázquez-Herrero, y López-García, 2023). En la educación, *ChatGPT* demuestra su utilidad pudiendo mejorar la experiencia de aprendizaje al generar contenido personalizado, ofrecer retroalimentación instantánea y adaptarse a las necesidades individuales de los estudiantes (Morales-Chan, 2023). También es capaz de potenciar la actividad en *marketing* mediante la automatización de la atención al cliente, la optimización del contenido o la generación de ideas creativas para campañas (Saputra, Nasution, y Dharma, 2023).

A pesar de su versatilidad y eficacia en múltiples áreas, el uso de *ChatGPT* ha experimentado una tendencia a la baja aproximadamente ocho meses después de su lanzamiento. En mayo de 2023, el sitio web de *ChatGPT* alcanza su cumbre con 1.850 millones de usuarios mensuales, convirtiéndose en la 17ª página más visitada en el mundo (Toni Vitali, 2023), marcando un hito en la historia de las tecnologías de *IA*. Sin embargo, de manera inesperada, a partir de ese mes, la plataforma experimenta una disminución constante en el número de usuarios, tendencia que persistió al menos hasta agosto de 2023 (Nerdynav, 2024) (ver Figura 1.3). Durante este periodo, surgieron diversas cuestiones éticas y sociales en torno a esta herramienta, tales como preocupaciones sobre la privacidad de los datos, la exactitud de la información generada y los posibles efectos en el empleo. Estas inquietudes podrían haber influido en la percepción pública de *ChatGPT*. Sin embargo, no se puede establecer con certeza si estas son las causas directas del declive en su uso (Farina y Lavazza, 2023). Es interesante observar que esta tendencia de disminución se alinea con el interés decreciente en las búsquedas de *Google* sobre “*ChatGPT*”, tal como se refleja en la Figura 1.2. Esto sugiere que el menor interés en la tecnología, según las búsquedas en línea, parece estar relacionado con la reducción en su uso práctico por parte de los usuarios. En cualquier caso, este cambio en la trayectoria de adopción de *ChatGPT* subraya la importancia de comprender las percepciones cambiantes de la sociedad sobre esta tecnología y las posibles implicaciones éticas y sociales que podrían estar influyendo en su uso. La percepción pública desempeña un papel crucial en la adopción, aceptación y consideraciones éticas relacionadas con la *IA* y los *LLM* (Qi, Pan, Lyu, y Luo, 2023).

En este contexto, las *Redes Sociales (RRSS)* emergen como una fuente invaluable de información para comprender la percepción ciudadana. Funcionan como canales para expresar tanto la identidad individual como la colectiva frente a otros individuos. Este entorno permite que ambas identidades se fortalezcan de manera simultánea y continua, posibilitando el rastreo de interacciones, la identificación de patrones y la comprensión de la dinámica de

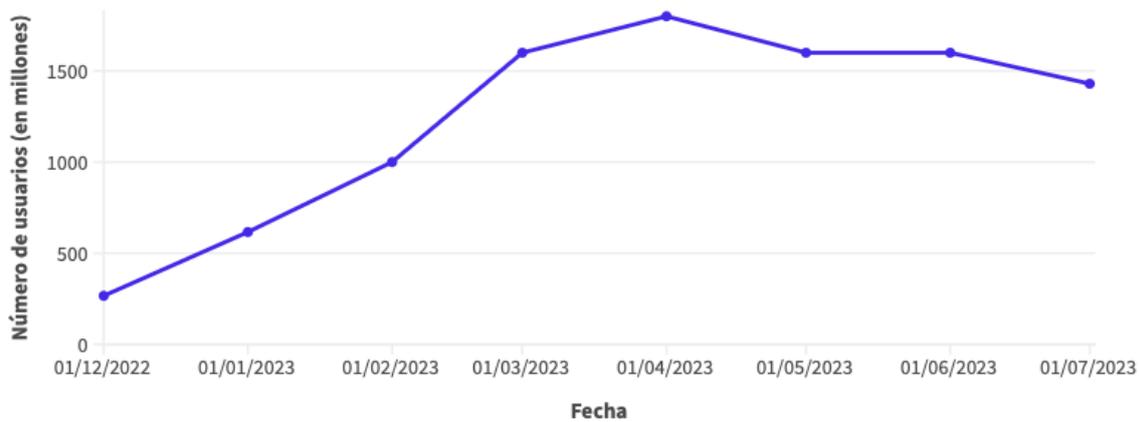


Figura 1.3: Evolución del número de usuarios de *ChatGPT*. Fuente de datos: (Nerdynav, 2024). Elaboración propia

difusión de información y opiniones en la sociedad (Del Prete y Redon Pantoja, 2020). Además, ofrecen una instantánea en tiempo real de la interacción social, donde los individuos intercambian constantemente ideas, opiniones y emociones, creando así una fuente de datos dinámica y actualizada sobre el tema en cuestión. La naturaleza globalmente inclusiva de estas plataformas amplía considerablemente el alcance del análisis, permitiendo la realización de estudios a escala global (Martos Carrión, 2011).

Los científicos sociales han demostrado una preferencia por el análisis en la red social *X*, anteriormente conocida como *Twitter* y donde sus publicaciones eran denominadas *tweets*. El potencial de estos posts radica en su contenido lingüístico conciso, limitado a 280 caracteres, enriquecido además con valiosos metadatos como marcas de tiempo, nombres de usuario y otros datos que contextualizan el análisis (Brooker, Barnett, y Cribbin, 2016). Esta interacción entre la *IA* y las *RRSS* proporciona un entorno dinámico donde las opiniones y actitudes del público pueden ejercer una influencia significativa en la adopción y el desarrollo de tecnologías revolucionarias. Por consiguiente, entender cómo la percepción pública se refleja y se modifica en las *RRSS* es esencial para comprender mejor las dinámicas sociales contemporáneas, identificar tendencias emergentes y anticipar cambios en la opinión pública. Este enfoque respalda la relevancia de las *RRSS* como fuente de información para el presente Trabajo de Fin de Grado (TFG).

1.2. Objetivos

1.2.1. Objetivo General

El presente TFG en *Business Analytics* tiene como objetivo principal obtener información relevante de la percepción pública sobre *ChatGPT*, una tecnología basada en modelos

de lenguaje preentrenados. Este análisis se llevará a cabo mediante la recopilación y procesamiento de datos de publicaciones en la plataforma *X*. El propósito es identificar las categorías de discusión predominantes, y evaluar el sentimiento general, lo que permitirá comprender la manera en la que la audiencia percibe y se relaciona con *ChatGPT* en el entorno digital de las *RRSS*. Para ello, se explorarán diferentes enfoques de análisis de texto y minería de datos que ofrezcan una visión integral de la opinión pública acerca de esta *Inteligencia Artificial Generativa (IAG)*.

1.2.2. Objetivos Específicos

El Objetivo General se puede desglosar en objetivos específicos que permiten una visión más concreta del estudio a realizar y, que se presentan a continuación:

- Destacar la importancia de estudiar y comprender la percepción pública sobre *ChatGPT* como *IAG* a través de *RRSS*.
- Realizar una revisión de la literatura científica para identificar y analizar las técnicas de minería de textos aplicables al análisis de datos provenientes de *RRSS*, especialmente aquellas enfocadas a la extracción de información relevante sobre percepciones ciudadanas hacia tecnologías emergentes y disruptivas.
- Aplicar técnicas de modelado de tópicos para identificar los temas predominantes en la red social *X* relacionados con *ChatGPT*, y desarrollar un análisis de sentimientos para evaluar la actitud y percepción general de los usuarios hacia el mismo.

1.3. Estructura del documento

El presente documento se estructura en cinco capítulos principales. En el Capítulo 2, se realiza una revisión detallada del estado del arte en técnicas de minería de texto y analítica de datos utilizadas para extraer información sobre la percepción pública. Se exploran investigaciones que estudian la percepción de tecnologías innovadoras, proporcionando una base sólida para este estudio. El Capítulo 3 presenta en detalle la metodología empleada, que abarca desde la selección y procesamiento del conjunto de datos a analizar, hasta el análisis descriptivo de los mismos. Se describen también las estrategias de modelado de tópicos y de análisis de sentimientos seleccionadas, brindando una visión completa de la metodología utilizada. En el Capítulo 4, se presentan los resultados de cada etapa de la metodología, mostrando de manera clara los datos claves obtenidos a lo largo del estudio. Por último, el Capítulo 5 resume las principales conclusiones del trabajo, resaltando las implicaciones y aportaciones más relevantes. Además, se señala el trabajo futuro que podría derivarse de este estudio, ofreciendo una perspectiva para investigaciones posteriores en el área de aplicación.

Capítulo 2

Percepción Pública sobre Nuevas Tecnologías a través de *RRSS*: Revisión de la Literatura

En la actualidad, las *RRSS* se han consolidado como una herramienta de comunicación fundamental, siendo espacios digitales de acceso generalizado donde convergen la interacción social, la difusión de información y la expresión de opiniones. La amplia participación, la accesibilidad pública y la diversidad de usuarios son atributos fundamentales de estas plataformas que las convierten en canales idóneos para capturar la percepción y opinión de las personas (Karamouzas, Mademlis, y Pitas, 2022). Concretamente, las publicaciones en plataformas como *X* representan una fuente inestimable de información. Al ser compartidas de manera pública, facilitan la expresión de opiniones en el contexto digital, generando debates en un ambiente informal y sin fronteras. Esta dinámica permite que los individuos expresen sus opiniones de manera libre y, al mismo tiempo, brinda a investigadores y analistas la oportunidad de analizar y comprender estas opiniones en tiempo real, proporcionando una visión enriquecedora del pensamiento colectivo (Baviera, 2017).

La adopción generalizada de las *RRSS* ha transformado la comunicación y la interacción de perspectivas en la sociedad actual. Esta revolución digital ha creado una oportunidad para obtener información relevante acerca de la percepción pública. Este enfoque de análisis se aplica al campo de estudio de las tecnologías innovadoras, que es el núcleo central de este trabajo. En particular, el análisis de *RRSS* y la minería de texto se han convertido en herramientas referentes para explorar las actitudes, opiniones y preocupaciones de la ciudadanía con respecto a avances tecnológicos disruptivos (Ahmad, Aftab, y Ali, 2017). En nuestra sociedad actual, obtener una visión precisa de cómo se perciben estas innovaciones es primordial, dado que estas percepciones pueden influir en la adopción y aceptación de los avances tecnológicos, y en última instancia, en su impacto en la sociedad. De esta manera, comprender la evolución de la percepción que el público muestra respecto a tecnologías in-

novadoras como *ChatGPT* es necesario para anticipar futuros desarrollos y tomar decisiones estratégicas. Estas tecnologías están en constante evolución, y por lo tanto, se requiere obtener una comprensión profunda y actualizada que guíe la toma de decisiones y asegure que estas innovaciones beneficien a la sociedad en su conjunto.

Especialmente dentro del campo de la analítica de textos en *RRSS*, el análisis de publicaciones de *X* presenta características únicas que lo hacen una herramienta valiosa para el estudio de la percepción ciudadana sobre las nuevas tecnologías. Su capacidad para realizar análisis en tiempo real, el acceso a una gran cantidad de datos y la autenticidad de las opiniones compartidas en la plataforma *X* la convierten en una fuente confiable de información. Como resultado, a lo largo de los años, se han realizado investigaciones significativas mediante el análisis de publicaciones de *X* centradas en tecnologías emergentes.

Por ejemplo, los servicios en la nube resultaron, en su momento, una tecnología innovadora en diversos campos, contando con un gran potencial asociado a los recursos y servicios que ofrecen a través de *Internet*. Así, se presentaron estudios para comprender las percepciones del público hacia proveedores de estos servicios como *Microsoft* y *Amazon* a través de sus productos: *Azure* y *Amazon Web Services (AWS)*, como lo evidencia el trabajo propuesto por (Qaisi y Aljarah, 2016). Esta investigación utiliza técnicas de análisis de sentimiento para evaluar la opinión de los usuarios de *X* (antes *Twitter*) sobre los proveedores mencionados mediante el uso de la técnica *Naïve Bayes (NB)*. El estudio analizó 3000 publicaciones en *X* de los dos proveedores mencionados: *Microsoft* y *Amazon*. *Azure*, del primero de los proveedores, mostró una mayor satisfacción entre los usuarios con un 65 % de polaridad positiva, superando al 50 % de *AWS* de *Amazon*. *Microsoft* también se destacó al tener un menor porcentaje de publicaciones negativas (25 %) en comparación con *AWS* (45 %). Estos resultados se traducen en un mayor número de personas satisfechas con el servicio ofrecido por *Microsoft*, al compararlo con *Amazon*. Además, el estudio proporciona recomendaciones específicas para cada una de las empresas en función de los resultados obtenidos a través del análisis. En particular, se sugiere que *AWS* podría beneficiarse de una mayor atención en su estrategia de *marketing* en *X* para mejorar la percepción del público. Para *Azure*, se estudia la oportunidad de aprovechar su polaridad positiva mediante un aumento en la promoción de ofertas y la generación de contenido atractivo en su página de *X*, lo cual podría fortalecer la satisfacción y lealtad de los usuarios.

De manera similar, la aparición de asistentes de *IA* como *Siri* de *Apple*, *Cortana* de *Microsoft* o *Google Assistant (GA)* de *Google* representa otra innovación en el ámbito tecnológico. El análisis de publicaciones de *X* también se ha empleado para comprender la evaluación ciudadana alrededor de estas nuevas tecnologías. Así, en el trabajo presentado por (Park y Seo, 2018) se emplea el diccionario *VADER (Valence Aware Dictionary for Sentiment Reasoning)* en un análisis de sentimientos para distinguir las diferentes percepciones hacia estos asistentes. El estudio reveló variaciones significativas en las polaridades de sentimiento (negativas, positivas y neutras) asociadas a cada asistente. De manera notable, *GA* se destacó por su ma-

yor satisfacción entre los usuarios, con una polaridad positiva del 34 %, superando a *Cortana* (24 %) y a *Siri* (15 %). En términos de percepciones negativas, *GA* registró tan solo un 2.5 %, en contraste con el 19.75 % de *Cortana* y el 31 % de *Siri*. *GA* es evaluado de manera más positiva que sus competidores. Sin embargo, los autores señalan que las técnicas de *Procesamiento del Lenguaje Natural (NPL)* presentan limitaciones importantes, especialmente en la identificación de emociones relacionadas con productos o servicios de *IA*, ofreciendo una base para futuras investigaciones en este ámbito.

Las tecnologías emergentes han surgido a lo largo de los años transformando diversos campos. Dentro del estudio de la biotecnología y la genética, se encuentran revolucionarias herramientas de edición genética como *CRISPR-Cas9 (Clustered Regularly Interspaced Short Palindromic Repeats)*. Esta innovadora tecnología tiene la capacidad de modificar el *ADN* humano, generando preocupaciones éticas y científicas, desencadenando un debate abierto en las *RRSS*. Una vez más, el análisis de publicaciones de *X* se presenta como una herramienta clave para comprender la percepción pública sobre la adopción de nuevas tecnologías. En este caso, el objetivo principal se basa en influir en la formulación de políticas y regulaciones éticas en torno a *CRISPR-Cas9*. De esta manera, el estudio propuesto por (Müller, Schneider, Salathé, y Vayena, 2020) analiza la evolución del sentimiento hacia esta tecnología relacionándola con eventos significativos del mundo real. Este estudio analizó más de 1.3 millones de publicaciones en *X* sobre *CRISPR-Cas9* entre 2013 y 2019, utilizando cuatro técnicas de análisis de sentimientos: *Bag of Words (BoW)*, *Sent2Vec* con *Support Vector Machines (SVM)*, y *BERT (Bidirectional Encoder Representations from Transformers)*. *BERT* se destacó como el mejor clasificador, revelando que la mayoría de las publicaciones de *X* eran positivas (52.3 %), seguidos por neutrales (40.3 %) y un menor porcentaje negativo (7.5 %). A pesar de la prevalencia de sentimientos positivos al principio, hubo un descenso notable en estos después de 2017, coincidiendo con preocupaciones relacionadas con *CRISPR-Cas9*, como efectos secundarios y controversias en edición genética. *BERT* también correlacionó picos de actividad en *X* con eventos del mundo real, demostrando una conexión entre la discusión en la plataforma y el discurso público.

Con el avance del tiempo, nuevas tecnologías continúan surgiendo en el panorama tecnológico, destacando en este caso la *Realidad Aumentada (RA)* y la *Realidad Virtual (RV)*. Estas tecnologías versátiles ofrecen aplicaciones en diversos campos, mejorando potencialmente los resultados en áreas como la educación y el entretenimiento. Un ejemplo destacado radica en la integración de la *RA* y la *RV* en el ámbito educativo, donde se espera que estas tecnologías motiven a los estudiantes a involucrarse activamente en sus procesos de aprendizaje, brindando la flexibilidad de poder hacerlo en cualquier momento y lugar. Nuevamente, el análisis de publicaciones de *X* se convierte en una herramienta esencial para comprender la percepción social sobre estas tecnologías innovadoras.

En este contexto, el análisis presentado por (Lampropoulos, Keramopoulos, Diamantaras, y Evangelidis, 2022) muestra que la adopción de tecnologías de *RA* y *RV* en la educación ha

ganado aceptación a nivel internacional. La inmersión y la interactividad de estas tecnologías crean entornos seguros que enriquecen la educación, facilitan el trabajo de los educadores y mejoran el rendimiento académico de los estudiantes. Para la identificación de temáticas relevantes, el estudio empleó el método de *Latent Dirichlet Allocation (LDA)*, logrando modelar once tópicos asociados a la *RA* y *RV*. Entre los más prominentes se encuentran la educación, el uso de nuevas tecnologías, medios digitales y sociales, así como su aplicación en marketing, publicidad, el sector industrial, la salud, los juegos y el fitness. En cuanto al análisis de sentimientos, se utilizaron técnicas avanzadas como *TextBlob*, *VADER* y el *National Research Council Canada Word-Emotion Association Lexicon (EmoLex)*, proporcionando una visión integral del impacto emocional de estas tecnologías. El análisis de más de 17 millones de posts de *X* indica que la mayoría de las actitudes son neutrales (59.58 % según *TextBlob* y 57.27 % según *VADER*), seguidas por una significativa percepción positiva (31.11 % en *TextBlob* y 35.49 % en *VADER*). *EmoLex* resalta emociones como confianza, alegría y anticipación. Estos resultados sugieren una inclinación hacia la neutralidad, posiblemente debido a un desconocimiento de los beneficios de la tecnología. El estudio implica que mejorar el acceso a equipos y habilidades técnicas en *RA* y *RV* podría favorecer una adaptación más exitosa.

En la actualidad, el concepto del *Metaverso* ha emergido como una innovación tecnológica con un potencial revolucionario que ha captado la atención de la sociedad en diversos ámbitos. Este nuevo paradigma se define como una combinación de tecnologías que incluyen *RRSS*, *RA*, *RV*, criptomonedas y juegos en línea. Dada su naturaleza en constante evolución, se presenta como un tema de gran interés para el análisis de la percepción pública, siendo los datos de la plataforma *X* una fuente idónea para obtener información en tiempo real. En este contexto, la investigación llevada a cabo por (Akkuzukaya, 2022) analiza la percepción del *Metaverso* en la población turca mediante el análisis de sentimiento en publicaciones de *X*, utilizando la biblioteca *TextBlob*. Los resultados mostraron que el 40 % de los sentimientos eran positivos, 25 % negativos y el resto neutrales, indicando una impresión generalmente favorable hacia el *Metaverso*. Sin embargo, el estudio también reveló preocupaciones sobre los posibles desafíos que el paradigma podría presentar para la identidad humana, planteando dudas sobre si la humanidad podría perder aspectos clave de su existencia espiritual y ética al sumergirse en lo virtual. Además, se señala que la especificidad de la población turca estudiada puede limitar la generalización de los resultados.

Dentro de la misma línea de trabajo, los investigadores han desarrollado diversos análisis para comprender aspectos específicos de este nuevo mundo. Dada su rápida expansión y evolución, es interesante estudiar su potencial para influir en una gran variedad de áreas. Uno de los aspectos que merece especial atención es la percepción del público en relación a la seguridad y la privacidad en este entorno. Así, el análisis de sentimientos presentado por (Al-Kfairy et al., 2023) propone un nuevo enfoque, utilizando herramientas de análisis de datos como *Stanford CoreNLP*, *MATLAB*, *RapidMiner*, *Orange Data Mining*, y estrategias

de *ML* como *SVM* y *NB*. Los resultados indican que el 59 % de los usuarios perciben la seguridad de manera positiva, 33 % neutral y 8 % negativo, mientras que en privacidad, el 66 % tiene una percepción positiva. Además, se empleó *Latent Semantic Analysis (LSA)* y *LDA* para el modelado de tópicos, identificando ciberseguridad y protección de datos como temas predominantes. Sin embargo, un examen manual posterior reveló que la mayoría de las publicaciones analizadas eran promocionales, lo cual disminuye la relevancia de los resultados. El estudio resalta las preocupaciones sobre la privacidad y seguridad de los niños y menores en la plataforma, así como inquietudes legales y de seguridad en el manejo de información personal en el *Metaverso*.

Finalmente, se aborda la tecnología innovadora más reciente, *ChatGPT*, que ha surgido recientemente y será objeto de estudio en esta investigación. Se han llevado a cabo diversas investigaciones sobre este modelo de *IAG* desde el lanzamiento de la aplicación por parte de *OpenAI*, enfocadas en comprender su integración en la sociedad. Teniendo en cuenta este objetivo, el estudio realizado por (Haque, Dharmadasa, Sworna, Rajapakse, y Ahmad, 2022) se enfoca en investigar la popularidad de la tecnología a través del análisis de publicaciones de *X*. Durante un período de 48 horas en diciembre de 2022, se recopilaron datos y se aplicaron técnicas avanzadas de modelado de tópicos y análisis de sentimientos. Mediante el uso de *LDA* junto con la técnica *Machine Learning for Language ToolKit (MALLET)*, se identificaron nueve temas principales de discusión entre los primeros adoptantes de la herramienta, que incluyen aspectos como interrupciones en el desarrollo de software, entretenimiento, *NPL* y el impacto en la educación. Posteriormente, se llevó a cabo un análisis de sentimientos individualizado para cada uno de estos tópicos. Se observó que los tópicos relacionados con el desarrollo de software y el entretenimiento obtuvieron los niveles más altos de polaridad positiva, registrando un 81 % y un 92 %, respectivamente. Sin embargo, el tópico centrado en la educación mostró una distribución más equilibrada, con un 52 % de sentimientos positivos, un 32 % negativos y un 16 % neutrales. A pesar de una percepción generalmente positiva en relación con *ChatGPT*, el estudio también identificó preocupaciones entre los usuarios en torno a posibles usos indebidos de esta tecnología, con un enfoque particular en su impacto potencial en el ámbito educativo.

La necesidad de investigación continua se hace evidente, especialmente para tecnologías en constante crecimiento, como es el caso de *ChatGPT*. La integración cada vez más común de la *IAG* en la vida cotidiana plantea cuestiones éticas y desafíos significativos. A pesar de ello, la satisfacción de los usuarios de *ChatGPT* no disminuye con el tiempo, aunque surgen críticas negativas a medida que aumenta la comprensión sobre la tecnología, según el estudio realizado por (Korkmaz, Aktürk, y TALAN, 2023). Este estudio se centra en analizar publicaciones en la plataforma *X* relacionadas con *ChatGPT* utilizando técnicas de analítica de texto, especialmente el análisis de sentimientos. Se emplearon tres métodos diferentes: *AFINN (Affective Norms for English Words)*, *Bing* y el *National Research Council (NRC)*. *Bing* clasificó las palabras en positivas y negativas, y a pesar de la presencia de palabras ne-

gativas, se observó que las emociones positivas predominaron en el estudio. Por otro lado, el análisis *NRC* de emociones reveló que, de 541,887 publicaciones de *X* analizadas, aproximadamente el 72 % contenía emociones positivas, el 22 % contenía emociones negativas y el 6 % eran neutrales. Esto respalda la tendencia generalmente positiva en la percepción de los usuarios hacia *ChatGPT* durante el año de su lanzamiento. El análisis *AFINN*, por su parte, evaluó las palabras utilizadas en las publicaciones relacionadas con *ChatGPT* en función de su valor emocional, confirmando que las emociones positivas predominan sobre las negativas. Sin embargo, el análisis también destacó las preocupaciones expresadas por las personas sobre posibles amenazas cibernéticas y la difusión de desinformación asociadas al crecimiento de *ChatGPT*. Estas preocupaciones resaltan la importancia de una investigación continua que pueda contribuir a la regulación de esta tecnología y al establecimiento de consensos en su uso en diversas áreas, dado su constante evolución y sus desafíos asociados.

En resumen, a lo largo de los años, hemos presenciado la incorporación de nuevas tecnologías en la vida cotidiana, generando impactos a menudo impredecibles. Las investigaciones detalladas hasta este punto han resaltado la importancia y utilidad del análisis de publicaciones de *RRSS* como *X* en relación con la percepción ciudadana de las tecnologías emergentes. Los resultados de estos estudios han aportado significativamente a la comprensión de la manera en que las personas perciben e integran estas tecnologías en sus vidas, al mismo tiempo que han identificado aspectos negativos y consideraciones éticas pertinentes. Estas conclusiones son relevantes para el desarrollo de regulaciones y la orientación del uso de estas tecnologías en diversos campos.

La Tabla 2.1 proporciona una visión integral de la variedad de metodologías empleadas en investigaciones sobre la percepción pública en el ámbito de las tecnologías emergentes. Esta síntesis facilita la extracción de conclusiones significativas de la revisión de literatura realizada. Se observa una notable variación en los tamaños de los conjuntos de datos analizados, abarcando desde unos pocos miles hasta millones de publicaciones en *X*, anteriormente conocidos como *tweets*. Esto indica la viabilidad de adoptar enfoques metodológicos diversos acordes con las distintas magnitudes de análisis. Además, los estudios analizados comparten similitudes en términos de métodos de adquisición de datos, centrados principalmente en datasets de publicaciones de *X*. El uso de filtros basados en palabras clave es una constante en estas investigaciones, sirviendo como un mecanismo esencial para enfocar los estudios en sus respectivos temas. Adicionalmente, se identifica la implementación de varias técnicas de restricción de datos, incluyendo filtros por fechas y por idioma, para refinar y contextualizar el análisis.

En continuidad con la diversidad de enfoques metodológicos identificados, los estudios analizados comparten un objetivo común: comprender la percepción pública sobre tecnologías innovadoras emergentes a través del análisis de publicaciones en *X*. Dentro del espectro del análisis de textos, estos estudios se dividen en dos categorías principales: análisis de sentimientos y modelado de tópicos. Algunos de estos trabajos integran ambas técnicas, mientras

que otros se concentran exclusivamente en una, decisión que depende en gran medida de los objetivos específicos de los investigadores y de los resultados deseados. En el campo del análisis de sentimientos, diversos algoritmos han sido implementados incluyendo *NB*, *VADER*, *BoW*, *BERT*, *NRC*, entre otros. Los enfoques más comúnmente empleados son *VADER* y *NB*. *VADER* es preferido por su capacidad para capturar con precisión emociones complejas expresadas por los usuarios, además de su eficiencia en el manejo de datos en tiempo real y grandes conjuntos de datos, lo que lo hace particularmente adecuado para el análisis de publicaciones en *X* (Park y Seo, 2018). En cuanto al modelado de tópicos, la técnica de *LDA* se destaca como la principal en los estudios revisados. Esta técnica es ampliamente reconocida y aceptada en la literatura de *Ingeniería del Software (IS)* (Haque et al., 2022), debido a su habilidad para manejar conjuntos de datos sin necesidad de anotaciones previas, requiriendo únicamente el conjunto de datos de texto y la definición del número específico de temas a identificar (Lampropoulos et al., 2022).

Siguiendo la línea de las investigaciones previamente analizadas, este *TFG* se enfoca en una temática afín, centrándose en la tecnología disruptiva más reciente que ha impactado en la sociedad: *ChatGPT*. El objetivo de este estudio es ampliar el conocimiento actual y monitorizar la evolución de las actitudes públicas hacia *ChatGPT* a medida que se integra en diversas áreas de aplicación. Para ello, se emplearán las técnicas *LDA* y *VADER*, elegidas por sus ventajas destacadas anteriormente. Los resultados de esta investigación ofrecerán una visión más completa y actualizada sobre la manera en la que el público percibe dicha tecnología emergente, contribuyendo así a un entendimiento más profundo de su impacto en la sociedad.

Tabla 2.1: Resumen de los estudios sobre el análisis de la percepción ciudadana al usar diversas tecnologías disruptivas.

Referencia	Tamaño del Dataset	Método de Adquisición	Objetivo	Algoritmo	Resultados
(Qaisi y Aljarah, 2016)	3.000 publicaciones de X	Filtrado por palabras clave: “AWS OR awscloud OR ec2cloud OR Amazon Web Services” y “Azure OR Microsoft Azure”.	Analizar la percepción de los usuarios de servicios en la nube realizando una comparativa entre los dos proveedores líderes, evaluando la opinión de los usuarios y proporcionando recomendaciones específicas para cada empresa basadas en los resultados obtenidos.	Análisis de Sentimientos: <i>NB</i> .	Los resultados indican que <i>Azure</i> tiene una polaridad positiva superior a la obtenida por <i>AWS</i> , lo que sugiere un mayor número de personas satisfechas con el servicio de <i>Microsoft</i> en comparación con el servicio de <i>Amazon</i> . Las recomendaciones específicas indican implementar una mejora en la estrategia de marketing para <i>AWS</i> y una promoción de ofertas para <i>Azure</i> .
(Park y Seo, 2018)	105.000 publicaciones de X aprox.	Filtrado por fechas: mes de noviembre de 2020. Filtrado por idioma: solo lengua inglesa. Filtrado por palabras clave: “Siri”, “Cortana” y “Google Assistant”.	Analizar la percepción de los usuarios de asistentes de <i>IA</i> para así comprender la satisfacción de los clientes y encontrar posibles mejoras en el futuro.	Análisis de sentimientos: <i>VADER</i> .	<i>GA</i> recibe una evaluación más positiva en comparación con <i>Cortana</i> y <i>Siri</i> . Además, se observa que el <i>NPL</i> aún no está completamente optimizado, sugiriendo la necesidad de avanzar en su desarrollo para investigar las emociones asociadas con productos o servicios de <i>IA</i> .
(Müller et al., 2020)	1.300.000 publicaciones de X aprox.	Filtrado por fechas: del 1 de enero de 2013 hasta el 31 de mayo de 2019. Filtrado por idioma: solo lengua inglesa. Filtrado por palabras clave: “CRISPR-Cas9”, o <i>hashtags</i> como “crispr”	Analizar la evolución de la percepción ciudadana hacia la tecnología de modificación genética “CRISPR-Cas9”, relacionándola con eventos significativos e identificar las principales preocupaciones éticas.	Análisis de sentimientos: <i>BoW</i> , <i>Sent2Vec</i> con <i>SVM</i> , <i>FastText</i> y <i>BERT</i> .	Los usuarios muestran un sentimiento, en media, positivo hacia la tecnología “CRISPR”. Sin embargo, destaca una negatividad más pronunciada al tratar su convergencia con embriones y humanos. Destaca la correlación entre la tendencia de sentimiento y los acontecimientos que tienen lugar en la vida real, evidenciando que la conversación online tiene una relación directa con la realidad.
(Lampropoulos et al., 2022)	17.300.000 publicaciones de X aprox.	Filtrado por fechas: de enero de 2010 a diciembre de 2020. Filtrado por idioma: solo lengua inglesa. Filtrado por palabras clave: “augmented reality” o “AR”, “virtual reality” o “VR” y “teach” o “learn” o “education” o “school” o “college” o “class” o “student”	Analizar la percepción ciudadana, actitudes y discusiones sobre la adopción e integración de la RA y la RV en la educación.	Análisis de sentimientos: <i>TextBlob</i> , <i>VADER</i> y <i>EmoLex</i> . Modelado de tópicos: <i>LDA</i> .	Se identificaron los principales temas emergentes como las nuevas tecnologías, el marketing y la publicidad o el uso de los medios digitales. Se concluye una aceptación internacional positiva de esta tecnología donde la mayoría de los datos analizados son neutrales o positivos, además de expresar emociones de confianza y alegría.
(Akkuzukaya, 2022)	Desconocido	Filtrado por idioma: solo lengua turca. Filtrado por palabras clave: “metaverso”, “metauniverso”, “universo de instancia”, “mundo falso”, “universo virtual”.	Analizar la percepción ciudadana hacia el concepto del <i>Metaverso</i> así como su interés por vivir experiencias en él.	Análisis de sentimientos: <i>TextBlob</i> .	Los usuarios son conscientes de la existencia y del desarrollo del <i>Metaverso</i> , así como del impacto que generará en la vida; y, se muestran predispuestos a una participación activa en el mismo. El estudio reconoce que los resultados pueden diferir al ampliar el alcance palabras clave así como los idiomas utilizados.

Referencia	Tamaño del Dataset	Método de Adquisición	Objetivo	Algoritmo	Resultados
(Al-Kfairy et al., 2023)	320.000 publicaciones de X aprox.	Filtrado por fechas: de octubre de 2021 a enero de 2023. Filtrado por palabras clave: “metaverso”, “seguridad”, “privacidad”	Analizar la percepción ciudadana hacia la seguridad y privacidad ofrecida en el <i>Metaverso</i> .	Análisis de sentimientos: <i>SVM</i> y <i>NB</i> . Modelado de tópicos: <i>LSA</i> y <i>LDA</i> .	Los usuarios tienen una percepción mayoritariamente positiva hacia la seguridad y la privacidad ofrecidas. Se destacan preocupaciones en relación con la seguridad y privacidad de los niños, así como inquietudes en cuanto a la legalización y seguridad de la información personal que se comparte en la plataforma.
(Haque et al., 2022)	10.732 publicaciones de X	Filtrado por fechas: del 5 de diciembre de 2022 al 7 de diciembre de 2022. Filtrado por idioma: solo en lengua inglesa. Filtrado por palabras clave: “ChatGPT”.	Analizar la percepción de los primeros usuarios de <i>ChatGPT</i> , el sentimiento generado hacia la tecnología, así como posibles preocupaciones.	Análisis de sentimientos: <i>NLTK</i> . Modelado de tópicos: <i>LDA</i> .	Los primeros usuarios de <i>ChatGPT</i> expresan sentimientos positivos hacia la nueva tecnología, destacando el uso de la misma para entretenimiento y creatividad, siendo la categoría modelada con sentimiento más positivo. Sin embargo se muestran también preocupaciones, como las implicaciones para los motores de búsqueda o el impacto en aspectos educativos.
(Korkmaz et al., 2023)	787.886 publicaciones de X	Filtrado por fechas: del 30 de noviembre de 2022 al 31 de enero de 2023. Filtrado por idioma: solo en lengua inglesa. Filtrado por palabras clave: “ChatGPT”.	Analizar la percepción pública sobre <i>ChatGPT</i> una vez que su uso comienza a ser generalizado, así como encontrar las posibles preocupaciones o implicaciones éticas relacionadas.	Análisis de sentimientos: <i>NRC</i> , <i>AFINN</i> , <i>Bing</i> .	Los usuarios de <i>ChatGPT</i> muestran una actitud positiva hacia la tecnología a medida que la misma se desarrolla. No obstante, las preocupaciones sobre sus posibles consecuencias o usos indebidos crece también acompañando a su desarrollo.

Capítulo 3

Metodología de Análisis de Datos

Este capítulo detalla la metodología adoptada en este *TFG*, enfocado en el análisis automático de publicaciones de la plataforma *X*. La metodología se desglosa en cinco secciones fundamentales, que estructuran el proceso de investigación. Inicialmente, se aborda la adquisición y preparación de los datos, seguido por la explicación de las técnicas para el pre-procesamiento de estos datos. Posteriormente, se profundiza en el análisis de *n-gramas*, seguido por el modelado de tópicos, y culminando con el análisis de sentimientos. La secuencia metodológica, ilustrada visualmente en la Figura 3.1, permite visualizar cada etapa y sus actividades específicas.

La primera sección, dedicada a la Adquisición y Preparación de Datos, implica la búsqueda y selección de datasets públicos pertinentes en el campo de estudio, alojados en repositorios reconocidos. Tras elegir la fuente de datos adecuada, se procede a la selección de variables relevantes para el análisis, considerando la temática y el contexto específicos del proyecto. En el Pre-procesamiento de Datos, se aplican diversas técnicas destinadas a limpiar y refinar la base de datos para el análisis textual. Por su parte, el Análisis de *n-gramas* se realiza mediante el cálculo de la métrica *Term Frequency – Inverse Document Frequency (TF-IDF)*, enfocada en identificar términos clave a través del análisis de palabras o secuencias de palabras. La sección de modelado de tópicos se centra en la aplicación del método *LDA* para identificar los temas principales en la base de datos. Finalmente, el análisis de sentimientos se lleva a cabo con la herramienta *VADER*, lo que permite interpretar las emociones asociadas a los textos analizados. Este enfoque integral busca, en última instancia, extraer información relevante asociada a la percepción pública sobre *ChatGPT*.

3.1. Adquisición y Preparación de los Datos

Para llevar a cabo el análisis de textos, es imprescindible contar con una base de datos robusta compuesta por publicaciones en *X*, pertinentes al campo de estudio. Tradicionalmente, la extracción de estos textos para el análisis de la percepción pública se realizaba mediante

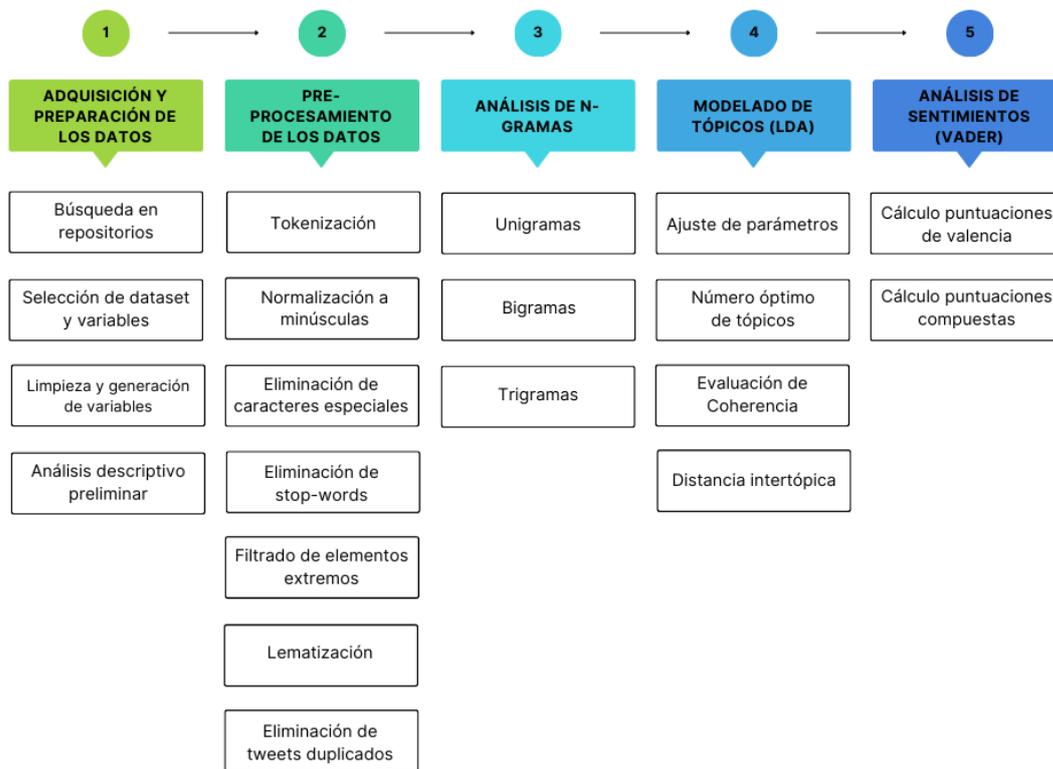


Figura 3.1: Fases de la Metodología de Análisis. Elaboración propia

el uso de la *Application Programming Interface (API)* de *X*. Esta herramienta facilitaba a investigadores y analistas la recolección de publicaciones de la base pública, empleando filtros como palabras clave, ubicación o idioma, para conformar un conjunto de datos adecuado para el estudio. No obstante, con la transición de *Twitter* a *X*, se han producido cambios significativos en la plataforma, incluyendo la restricción del acceso gratuito a su *API*. En consecuencia, este proyecto ha adaptado una metodología paralela, orientándose hacia la exploración de repositorios públicos. Estos brindan acceso a conjuntos de datos de publicaciones ya existentes y disponibles gratuitamente, que en muchas ocasiones fueron recogidas previo a estos cambios. Este enfoque asegura la disponibilidad de datos relevantes y pertinentes para el análisis propuesto.

Un repositorio de bases de datos es un recurso digital que almacena y facilita el acceso a conjuntos de datos para su uso y análisis. Estos repositorios, a menudo accesibles al público sin coste asociado, son cruciales para investigadores que buscan datos relevantes en una variedad de campos y temáticas. *Kaggle*, por ejemplo, es una plataforma en línea que proporciona acceso a bases de datos subidas por su comunidad de usuarios. Esta permite la búsqueda mediante palabras clave, facilitando la localización de conjuntos de datos acordes con el enfoque de estudio específico. Para este proyecto, se emplearon términos como

“ChatGPT”, “tweets” (concepto utilizado previamente para referirse a las publicaciones de X) y “public perception” para filtrar y seleccionar bases de datos pertinentes, las cuales varían en características como el número de registros y de variables.

La elección del conjunto de datos para este estudio se basa en la calidad y relevancia de la fuente. Es fundamental evaluar la pertinencia de las variables recogidas en relación con el objetivo del estudio, así como considerar la cantidad de registros disponibles. El tamaño del conjunto de datos es un aspecto clave, especialmente durante el modelado de tópicos y el análisis de sentimientos. Los resultados de estos procesos serán precisos en la medida en que la muestra de datos sea representativa. Se busca un equilibrio entre un volumen sustancial de registros y una cantidad de variables manejable, que no solo permita un procesamiento eficiente sino también garantice la obtención de resultados significativos en el área de estudio.

3.2. Pre-procesamiento de los Datos

Con el fin de realizar un análisis de texto efectivo, la limpieza y pre-procesamiento de los datos son pasos fundamentales. Este proceso implica una serie de técnicas que mejoran la calidad de los datos al eliminar el ruido y asegurar un formato adecuado para el análisis. Las diversas técnicas empleadas en este estudio se ilustran en la Figura 3.2 y se detallan a continuación.

La tokenización es el primer paso en este proceso, el cual consiste en descomponer los textos de la base de datos en unidades mínimas de análisis, conocidas como tokens. Por ejemplo, en la publicación: “IA como *ChatGPT* va a reemplazar a *Google*.”, la tokenización resulta en los siguientes tokens: “IA”, “como”, “ChatGPT”, “va”, “a”, “reemplazar”, “a”, “Google”, “.”. Esta descomposición facilita la manipulación y procesamiento de los textos, convirtiendo la tokenización en la base para la aplicación de técnicas subsecuentes (Orquín, 2009). Dado el elevado volumen de tokens generados, es necesario reducir su cantidad para un procesamiento más eficiente, asegurándose de no eliminar información relevante. Se comienza con la normalización de términos a caracteres en minúsculas, como transformar “Google” en “google”, lo que contribuye a la uniformidad en el tratamiento de los datos. Esta normalización asegura que las variaciones en el uso de mayúsculas y minúsculas no afecten al análisis, evitando que el mismo término sea contabilizado como entidades diferentes.

Además, se eliminan caracteres especiales que no contribuyen al contenido del análisis. Esto incluye signos de puntuación, números (cuando no son relevantes para la temática), acentos y diacríticos, mejorando así la estandarización del texto. Los emoticonos y caracteres especiales como @ (usado en menciones) y # (en *hashtags*), así como caracteres no alfanuméricos como & o %, también se eliminan para centrarse exclusivamente en el contenido textual. Por último, se descartan URL, hipervínculos y elementos similares presentes en las publicaciones de X , ya que generalmente carecen de contenido relevante para el análisis.

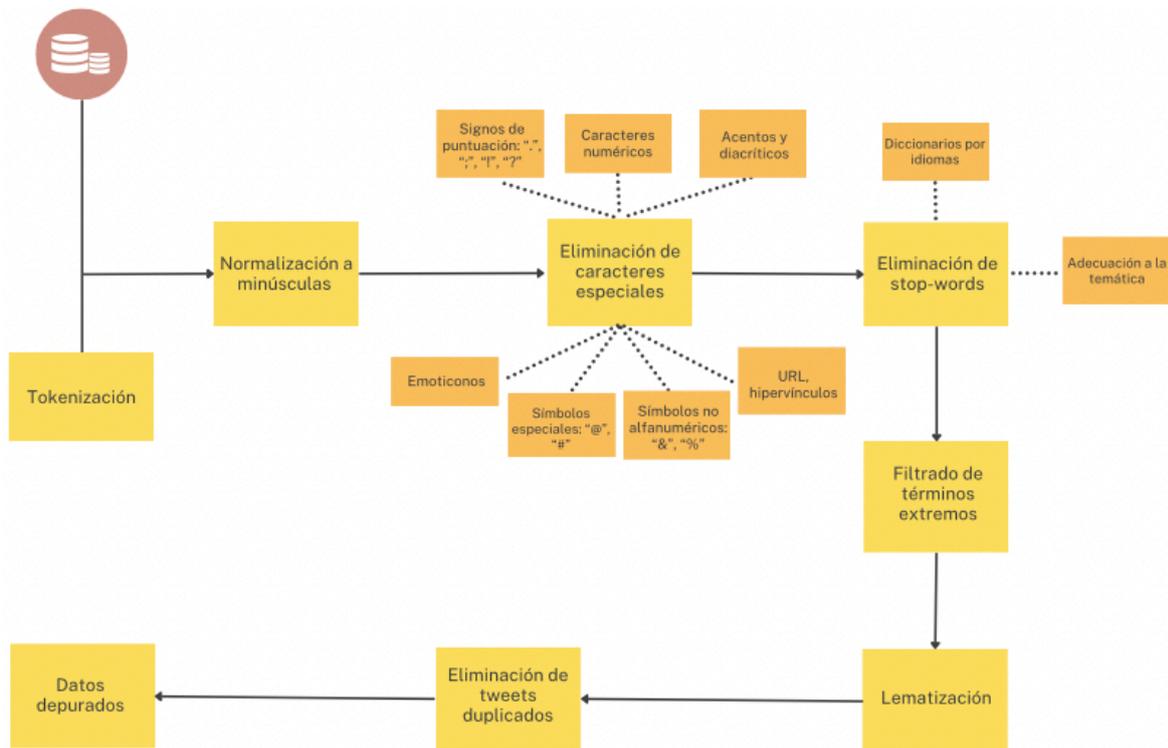


Figura 3.2: Fases en el Pre-procesamiento de datos. Elaboración propia

Siguiendo lo ilustrado en la Figura 3.2, la siguiente fase del pre-procesamiento de texto implica la eliminación de las llamadas *stop-words* o palabras vacías. Estas son palabras frecuentes en el lenguaje que, sin embargo, carecen de contenido significativo y varían según el idioma. Por ejemplo, en español palabras como “de”, “la”, “que”, “el”, “en”, “y”, “a”, “los”, “del”, “por”, “un” y en inglés “i”, “me”, “we”, “is”, “what”, “which”, “that”, y “this” son consideradas palabras vacías. Generalmente, preposiciones, artículos y conjunciones se eliminan para enfocarse en la temática relevante del texto. Esta tarea se facilita mediante el uso de diccionarios de *stop-words*, aunque es recomendable personalizarlos para cada análisis. En este estudio, incluir “chatgpt” como *stop-word* es estratégico, ya que el dataset se centra en esta temática y se conoce con anterioridad su presencia en el mismo. Así es posible reducir el volumen de procesamiento sin perder información relevante.

Posteriormente, se lleva a cabo un filtrado de términos extremos, eliminando aquellos que aparecen muy poco (menos del 2%) y los que son demasiado comunes (más del 95%) en el conjunto de datos. Este proceso ayuda a enfocar el análisis en información relevante y a identificar patrones de forma clara y concisa. El siguiente paso es la lematización, la cual consiste en transformar las formas flexionadas de una palabra a su base, como convertir “programación”, “programo” y “programando” en “programar”. Este proceso reduce la complejidad del texto manteniendo la integridad del contenido, ya que el lema engloba todas sus variantes. Finalmente, se elimina la información duplicada, asegurando que cada publicación sea única y contribuya significativamente al análisis. Esta etapa es fundamental para obtener

resultados precisos y significativos.

La etapa de pre-procesamiento descrita previamente se aplicará principalmente en el modelado de tópicos. Es importante destacar que para el análisis de sentimientos de las publicaciones se adoptará una estrategia distinta. Para este, se preservarán las puntuaciones, emoticonos y *stop-words*, y se evitará la normalización del texto. La razón es que estos componentes pueden aportar información significativa sobre el sentimiento manifestado en los mensajes. Emoticonos y signos de puntuación, por ejemplo, suelen ser indicadores claros de emociones y tonalidades, de gran relevancia al entender el contexto emocional de las publicaciones. Manteniendo estos elementos, el análisis de sentimientos logra una interpretación más precisa de las emociones y posturas de los usuarios frente a determinados temas, tal como *ChatGPT*, lo que resulta relevante al caracterizar la percepción pública sobre tecnologías emergentes. Así, en el análisis de sentimientos, el pre-procesamiento de datos se centrará exclusivamente en la eliminación de elementos como *hashtags*, URLs, menciones y cifras, para limpiar el texto sin omitir detalles importantes para la interpretación emocional.

3.3. Exploración de *N-Gramas*

Tras completar el pre-procesamiento de las publicaciones, obteniendo así un corpus depurado y libre de ruido, se procede a un análisis descriptivo de *n-gramas*. Este análisis implica la exploración de tokens tanto de forma individual como en secuencias, permitiendo la identificación de patrones lingüísticos. Un *n-grama* se define como una secuencia de n tokens consecutivos, donde n representa cualquier número natural. Por ejemplo, un unigrama consta de un solo token, un bigrama de dos tokens consecutivos, un trigramas de tres, y así sucesivamente. El análisis de *n-gramas* tiene como objetivo discernir las estructuras y patrones prevalentes en el lenguaje del texto. Esta técnica es fundamental para descubrir las palabras o combinaciones de palabras, así como los temas, que aparecen con mayor frecuencia en el corpus analizado, proporcionando una base para comprender las tendencias y los temas dominantes en las publicaciones relacionadas con *ChatGPT*.

Para cuantificar numéricamente la relevancia de cada término en un documento, se emplea el método *TF-IDF*. Este procedimiento está diseñado para asignar un peso específico a los términos o tokens contenidos en un documento, basándose en dos conceptos clave. El primero es la *Frecuencia de Término (TF)*, que mide la frecuencia con la que un token aparece en un documento determinado. El segundo es la *Frecuencia Inversa de Documento (IDF)*, que evalúa qué tan común o raro es un token en el conjunto total del corpus (Havrlant y Kreinovich, 2017). El valor de *TF-IDF* para un término específico (t) en un documento dado (d) se calcula multiplicando estos dos factores:

$$TF - IDF(d, t) = TF(d, t) \cdot IDF(t) \quad (3.1)$$

Específicamente, la TF se define como el número de veces que un término específico (t) aparece en un documento (d), en relación con el número total de términos en ese documento (Al-Obaydy, Hashim, Najm, y Jalal, 2022), tal y como ilustra la Ecuación 3.2. Esta métrica indica tanto la frecuencia del token como su relevancia dentro de un conjunto de palabras.

$$TF(d, t) = \frac{f_{d,t}}{\sum_{t' \in d} f_{d,t'}} \quad (3.2)$$

donde $f_{d,t}$ representa la frecuencia del término (t) en el documento analizado (d), sugiriendo que a mayor número de apariciones de un término, mayor es su importancia en el contexto de dicho documento. Por otro lado, $\sum_{t' \in d} f_{d,t'}$ simboliza la suma total de las frecuencias de todos los términos (t') presentes en el documento (d). Al dividir la frecuencia de un término por este total, se obtiene un valor de TF normalizado, que refleja la frecuencia del término en proporción a la longitud total del documento. Asimismo, la métrica IDF calcula la frecuencia del término analizado dentro del corpus como conjunto. Esta medida, que se detalla en la Ecuación 3.3, evalúa la singularidad de un término basándose en su distribución a través del conjunto de textos, proporcionando una perspectiva de la relevancia del token más allá de un único documento (Al-Obaydy et al., 2022).

$$IDF(d) = \log \left(\frac{D}{\{d \in D : t \in d\}} \right) \quad (3.3)$$

El uso del logaritmo en la fórmula de IDF se incluye con el fin de acentuar las diferencias entre términos que son muy frecuentes y aquellos que son menos comunes en el corpus. Esto permite identificar y dar más peso a los términos únicos, que son potencialmente más informativos. En esta fórmula, D representa el número total de documentos en el corpus. El denominador $\{d \in D : t \in d\}$ indica la cantidad de documentos que contienen el término t . Un valor más alto de IDF implica que un término es raro en el corpus, mientras que un valor bajo sugiere que es frecuente.

Al combinar TF con IDF , se puede obtener un balance entre la frecuencia local del término y su singularidad en el corpus, proporcionando así una medida más holística de su importancia en el análisis de textos. La Figura 3.3 visualiza este balance, mostrando en el eje horizontal la TF y en el eje vertical la IDF . Cada punto representa un término único dentro del corpus, con su tamaño y color correspondientes al valor de $TF-IDF$: mientras más grande y más cercano al rojo, mayor es el valor que toma el término. En la gráfica, los puntos hacia el extremo derecho, con alta TF , indican términos que aparecen con frecuencia en un documento particular pero no necesariamente a través de todo el corpus. Por otro lado, los puntos más altos indican términos con alta IDF , es decir, que son menos comunes en el corpus. Los puntos que se encuentran en la parte derecha de la gráfica y hacia arriba, que son rojos y con valores altos, representan términos que son frecuentes en documentos específicos y al mismo tiempo raros en el corpus completo, sugiriendo que estos términos son altamente

relevantes y específicos del tema o documento. Por el contrario, términos situados en la parte inferior y hacia la izquierda, que son azules, y están asociados a valores pequeños, tienden a ser comunes y posiblemente menos informativos.

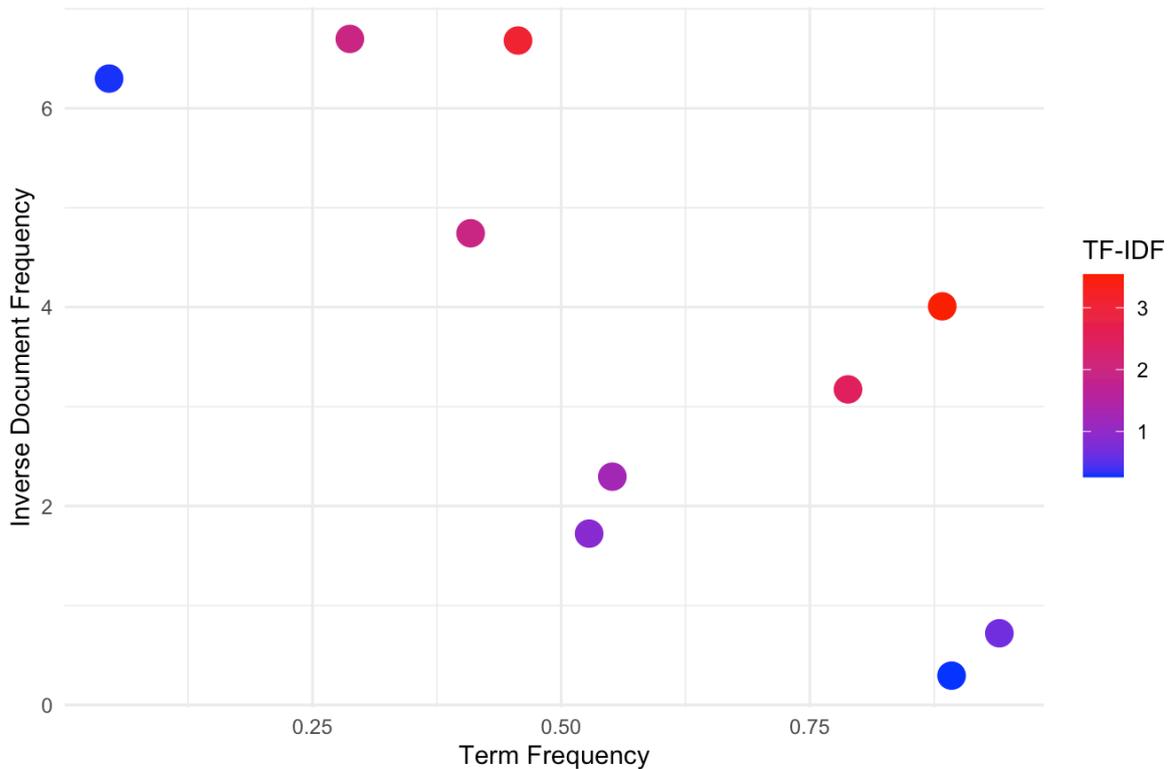


Figura 3.3: Representación de los valores de $TF-IDF$ según los valores tomados por sus métricas. Elaboración propia

3.4. Modelado de Tópicos

El modelado de tópicos, una técnica desarrollada en el ámbito del *NPL*, se utiliza para detectar y clasificar los temas predominantes dentro de un gran volumen de texto. Esta técnica tiene múltiples aplicaciones, como la clasificación automática de documentos, la organización temática de contenidos y la condensación de grandes cantidades de información. Es versátil en su uso, adecuada para analizar desde publicaciones en plataformas de medios sociales hasta reseñas de clientes, así como literatura académica y reportajes periodísticos. El objetivo del modelado de tópicos es revelar la estructura temática latente en un corpus, identificando los asuntos principales que se discuten (Ibáñez-Sosa, 2023). En el contexto de este trabajo, se implementa el modelado de tópicos en los datos extraídos de la red social *X*. La implementación de esta técnica ofrece una perspectiva exhaustiva de las discusiones en línea, abarcando desde las tendencias más populares hasta las perspectivas individuales. Al aplicar el modelado de tópicos a las publicaciones, se obtiene un entendimiento enriquecido

de la diversidad de temas y de la dinámica conversacional en la plataforma, proporcionando información valiosa sobre los intereses y preocupaciones de los usuarios.

Como se destaca en la Tabla 2.1 de la Revisión de Literatura, el enfoque *LDA* emerge como la técnica preferida para el modelado de tópicos en estudios previos. Esta técnica ha demostrado ser altamente efectiva para discernir tópicos en vastos conjuntos de datos textuales, tal y como se ha documentado en varios estudios analizados en el Capítulo 2. *LDA* es un modelo generativo, basado en el cálculo de probabilidades, que se utiliza para descubrir la estructura temática latente en colecciones de documentos. Este enfoque opera bajo la hipótesis de que los documentos son combinaciones de varios tópicos, donde cada tópico se define por una distribución específica de palabras (Blei, Ng, y Jordan, 2003).

Los corpus textuales en estos estudios tienden a ser amplios y complejos, incluyendo un elevado número de términos que pueden conducir a problemas de alta dimensionalidad. Aunque la técnica *TF-IDF*, descrita previamente, asigna valores a las palabras basándose en su frecuencia y unicidad, puede resultar insuficiente en grandes corpus por no capturar las interrelaciones temáticas entre documentos. *LDA* ofrece una solución a estas limitaciones. Al combinar *LDA* con *TF-IDF*, se aborda el problema de alta dimensionalidad y se enriquece la capacidad de clasificación y predicción de textos. Mientras que *TF-IDF* se enfoca en la frecuencia de términos individuales, *LDA* profundiza en la identificación de patrones temáticos. Esta integración de técnicas resuelve los desafíos inherentes y crea una sinergia que mejora significativamente la precisión en la clasificación de texto (Onan, Korukoglu, y Bulut, 2016). Esta estrategia aporta una visión más completa al analizar conjuntos de datos textuales extensos.

La lógica subyacente en *LDA* se fundamenta en la premisa de que, los textos dentro de un corpus están compuestos por una mezcla de varios tópicos, lo cual se ilustra en la Figura 3.4. Cada documento en el corpus puede contener una combinación de estos tópicos en diferentes proporciones. A través del análisis de patrones de co-ocurrencia y frecuencias de palabras, *LDA* agrupa palabras en clústeres semánticamente coherentes. Estos clústeres, o conjuntos de palabras que habitualmente aparecen juntos, se interpretan como tópicos, y las palabras agrupadas bajo cada uno de estos clústeres se consideran relacionadas con un tema específico. Bajo este modelo, se concibe que cada documento es una mezcla de tópicos, y que cada tópico es, a su vez, una colección de palabras con ciertas probabilidades de ocurrencia. *LDA* utiliza la distribución de estas palabras a través de los documentos para inferir la estructura temática latente del corpus. Este enfoque probabilístico y generativo destaca por su capacidad para revelar patrones temáticos y relaciones que no están explícitamente etiquetadas, facilitando así la comprensión de grandes volúmenes de datos textuales (Ibáñez-Sosa, 2023).

En pocas palabras, *LDA* postula que los documentos en un corpus resultan de la combinación de diversos temas. Las palabras que constituyen estos documentos no son aleatorias; por el contrario, se considera que son indicativas de los temas subyacentes. Así, cada texto no es más que una mezcla de tópicos, los cuales a su vez emergen a partir de las palabras que

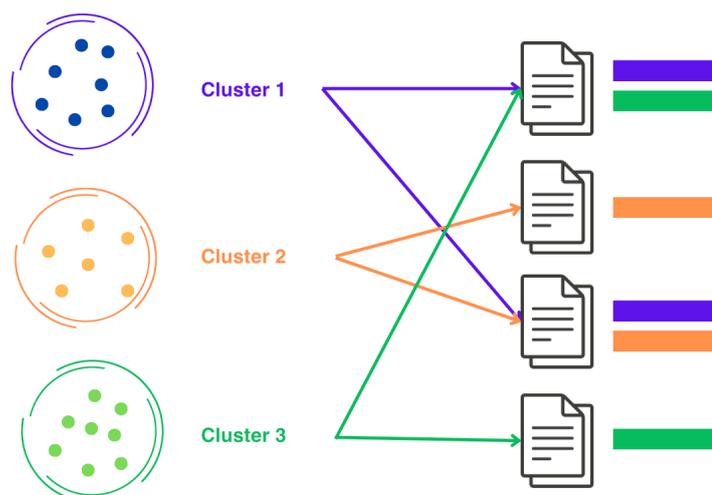


Figura 3.4: Representación de la lógica de clusterización detrás de la técnica *LDA*.
Elaboración propia

los caracterizan. Este modelo se rige por un proceso iterativo que se caracteriza por alcanzar la asignación más adecuada de tópicos a cada documento, un proceso que se puede observar detalladamente en la Figura 3.5.

Para desglosar el mecanismo generativo de *LDA*, es importante comprender dos distribuciones de probabilidad clave que rigen el modelo:

- **La distribución de tópicos por documento (identificada como θ):** Esta distribución refleja la probabilidad de que cada tópico contribuya a un documento específico. Por ejemplo, en el análisis de publicaciones de X , θ puede indicar la probabilidad de una publicación a tratar sobre uno o más tópicos determinados.
- **La distribución de palabras por tópico (identificada como φ):** Esta distribución señala la probabilidad de que ciertas palabras estén asociadas con un tópico específico. En resumen, φ define el perfil de un tópico en términos de las palabras que lo componen.

Las distribuciones de tópicos por documento y de palabras por tópico en *LDA* se modelan utilizando la distribución de Dirichlet, la cual es clave en la representación de la variabilidad y la incertidumbre en la asignación de tópicos y palabras a lo largo de los documentos. Específicamente, la distribución de Dirichlet, definida como una generalización multivariante de la distribución binomial, permite una construcción probabilística flexible en la generación de textos y la identificación automática de tópicos en conjuntos de datos textuales (Lin, 2016). En el contexto de *LDA*, la distribución de Dirichlet se caracteriza por dos parámetros fundamentales (Blei et al., 2003):

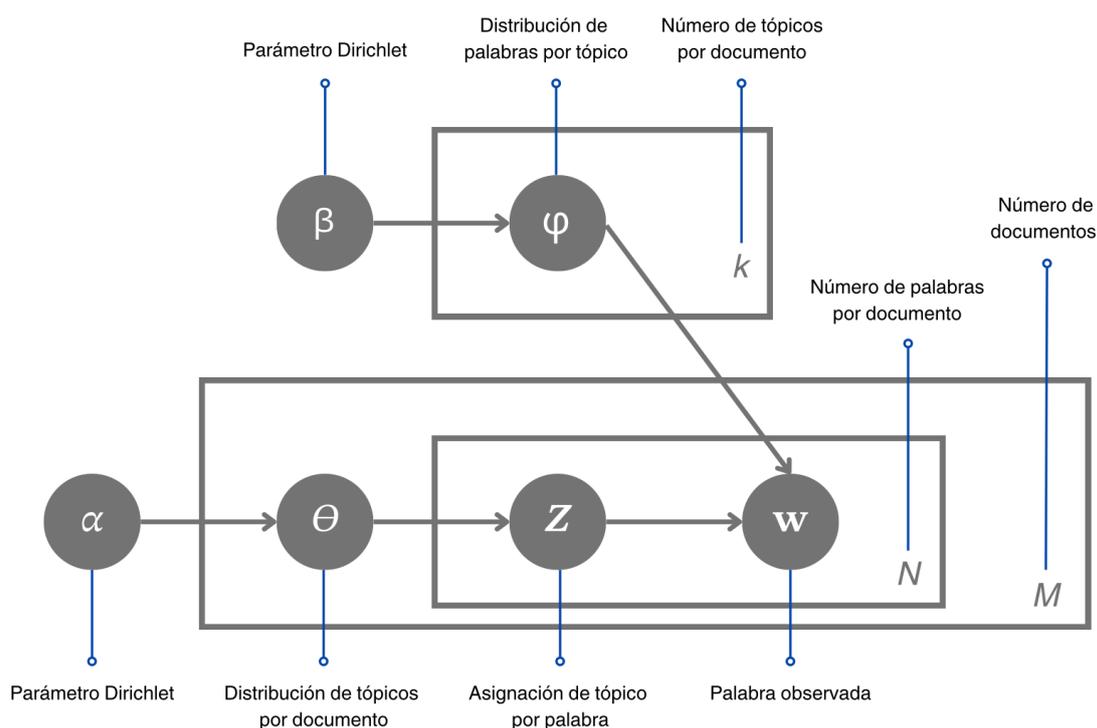


Figura 3.5: Diagrama descriptivo de la técnica *LDA*. Elaboración propia

- **El primer parámetro Dirichlet (α):** Este parámetro tiene un papel significativo en la distribución de tópicos por documento. Un valor elevado de α sugiere que un documento podría incorporar una mezcla amplia de varios tópicos, presentando así una diversidad temática considerable. Por el contrario, un valor bajo de α sugiere que los documentos tenderán a estar influenciados por un número limitado de tópicos predominantes.
- **El segundo parámetro Dirichlet (β):** Este parámetro modela la distribución de palabras por tópico. Un β alto implica que cada tópico puede abarcar una extensa variedad de palabras, mientras que un β bajo indica que los tópicos consistirán en grupos más reducidos de palabras clave.

Además de los parámetros de Dirichlet previamente mencionados, es importante considerar otros elementos clave en el modelo *LDA*. M representa el número total de documentos en el corpus, que en este estudio se corresponde con la cantidad de publicaciones de X recopiladas. La cantidad de palabras contenidas en cada documento se denota como N , mientras que la cantidad de tópicos distintos que se desea identificar en cada documento se representa por k . Se asume que cada documento M conforma una mezcla de estos k tópicos, y cada tópico a su vez es una distribución de palabras que se relacionan por la frecuencia con la que aparecen a través de los documentos.

El modelo *LDA* establece un proceso iterativo para explicar la generación de palabras en cada documento. Se concibe que cada documento M consiste en un conjunto de palabras N , cada una de las cuales es generada por uno de los k tópicos. La distribución de tópicos por documento, simbolizada por el parámetro θ , especifica las probabilidades relativas de los tópicos presentes en el documento. Para cada palabra W en el documento M , se elige un tópico Z de manera aleatoria, basándose en θ . A continuación, cada palabra es seleccionada de la distribución de palabras φ asociada con el tópico Z elegido. Este proceso se repite para todas las palabras en todos los documentos, generando así todo el corpus textual. Durante cada iteración, se ajusta la asignación de tópicos para las palabras, mejorando progresivamente la estimación de las distribuciones θ y φ hasta que el modelo converge a una representación estable de la estructura temática del corpus.

Para establecer el número óptimo de tópicos en un modelo *LDA*, se emplea un enfoque basado en la coherencia de tópicos. Este método implica la generación de una serie de modelos *LDA*, variando el número de tópicos (k) en cada uno, y seleccionando el modelo que exhiba la mayor coherencia temática. A diferencia de otros parámetros, como las distribuciones de Dirichlet, que pueden inicializarse con valores predeterminados, el valor de k debe ser configurado de antemano. Un tópico coherente se caracteriza por agrupar palabras significativamente relacionadas, haciendo que la coherencia actúe como un indicador de la claridad y precisión en la diferenciación temática. Mediante la experimentación con distintos valores de k , se busca identificar aquel que maximice la coherencia, indicando así el número óptimo de tópicos que facilita una separación y articulación semántica óptima entre ellos. El valor de k que alcanza la coherencia más elevada se considera el más apropiado para analizar el corpus en cuestión, proporcionando una base para la interpretación de las categorías de discusión identificadas (Onan et al., 2016).

En el marco del modelado de tópicos aplicado a las publicaciones en X , una técnica crucial es el análisis de la distancia intertópica, llevado a cabo mediante el uso del paquete *PyLDavis*. Este análisis se fundamenta en la divergencia de *Jensen-Shannon*, una métrica que cuantifica la distancia entre distribuciones de probabilidad. En este contexto, permite evaluar la diferencia entre los tópicos basándose en la distribución de palabras que los define, ofreciendo una perspectiva clara de cuán distintos son los tópicos entre sí. *PyLDavis*, una librería diseñada para facilitar la interpretación visual de los tópicos derivados del análisis *LDA*, emplea esta divergencia para calcular y representar la distancia intertópica (Hammoe, 2018). Esta funcionalidad permite visualizar la separación entre tópicos en un espacio multidimensional, proporcionando una herramienta valiosa para la evaluación y comprensión de la estructura temática del corpus analizado. Así, el análisis de distancia intertópica complementa el enfoque basado en la coherencia de tópicos, enriqueciendo el proceso de determinación del número óptimo de tópicos y mejorando la interpretación de los patrones temáticos presentes en las publicaciones de X (Ré, Prato, y Lamberti, 2008).

En resumen, la aplicación del modelo *LDA* da lugar a un conjunto de tópicos que propor-

ciona una visión estructurada y significativa de los patrones temáticos presentes en el corpus. Cada tópico se define por una distribución de palabras y representa una categoría semántica que abarca conceptos y temas específicos dentro del conjunto de documentos. Al mismo tiempo, cada documento se describe por una distribución de tópicos que refleja la mezcla de temas tratados. Este enfoque probabilístico no supervisado es eficaz para identificar de manera automática las estructuras temáticas latentes en datos textuales extensos. La implementación de *LDA* en el análisis textual facilita una comprensión detallada de la organización temática inherente a grandes colecciones de texto, convirtiéndose en una herramienta analítica esencial para la extracción de conocimiento en una amplia gama de campos académicos y aplicados.

3.5. Análisis de Sentimientos

El análisis de sentimientos, una enfoque ampliamente usado dentro del *NPL*, se especializa en la extracción automática de información subjetiva contenida en textos. Utilizando diversas técnicas computacionales, este enfoque evalúa la polaridad de los textos (identificando si transmiten sentimientos positivos, negativos o neutros) y es esencial para el procesamiento automático de opiniones, emociones y subjetividades expresadas en lenguaje natural (Sobrino Sande, 2018). En el contexto de estudios que analizan publicaciones de *RRSS*, el análisis de sentimientos es particularmente valioso para capturar las reacciones espontáneas y directas del público. En particular, esta técnica no solo reconoce patrones emocionales sino que también se ajusta dinámicamente a los cambios en el sentimiento colectivo, proporcionando así orientación para el desarrollo de estrategias comunicativas y de mercado. En pocas palabras, al analizar el lenguaje informal y las expresiones subjetivas en las publicaciones de *RRSS* como *X*, se revelan matices emocionales de gran importancia para comprender percepciones ciudadanas en un gran rango de aplicaciones (Sarlan, Nadam, y Basri, 2014).

Tras la revisión de la literatura en el área, resumida en la Tabla 2.1, se observa que *VADER* es la técnica predominante en estudios previos de análisis de sentimientos. Este método, que combina un enfoque léxico y reglas específicas, está especialmente diseñado para interpretar emociones en el contexto de las *RRSS*. *VADER* destaca por ser una herramienta de código abierto y gratuita, lo que facilita su amplio acceso. Su metodología única, que evalúa no solo la polaridad de las palabras sino también su disposición en el texto, le permite determinar con precisión la intensidad y orientación de las emociones expresadas. Dada su adaptabilidad a lenguajes informales y su habilidad para discernir matices sutiles, *VADER* resulta especialmente efectivo para el análisis de sentimientos en *RRSS*, donde las interacciones a menudo incluyen lenguaje coloquial, emoticonos y el uso de sarcasmo o ironía. (Elbagir y Yang, 2019).

VADER, concebido como un diccionario léxico, fue creado específicamente para analizar

expresiones humanas en diversos contextos. Este diccionario se distingue de otros similares por su eficacia en evaluar e identificar sentimientos. Para lograr una aproximación más precisa al lenguaje humano, se han incorporado una serie de reglas específicas en *VADER*, las cuales enriquecen su capacidad para interpretar matices y contextos variados del lenguaje:

- **Puntuación:** El uso de signos de exclamación aumenta la magnitud de la intensidad del sentimiento sin modificar la orientación semántica. Por ejemplo, “¡ChatGPT es muy útil!!!” se percibe como más intenso que “ChatGPT es muy útil”.
- **Uso de mayúsculas:** El uso de letras mayúsculas para resaltar una palabra relevante para el sentimiento, en presencia de otras palabras en minúsculas, aumenta la magnitud de la intensidad del sentimiento sin afectar la orientación semántica. Por ejemplo, “Es un programa GENIAL” transmite más intensidad que “Es un programa genial”.
- **Modificadores de grado:** Los modificadores de grado, como “extremadamente” o “relativamente”, aumentan o disminuyen la intensidad del sentimiento. Por ejemplo, “ChatGPT es extremadamente bueno” es más intenso que “ChatGPT es bueno”, mientras que “ChatGPT es relativamente bueno” reduce la intensidad.
- **Conjunción “pero”:** Esta conjunción indica un cambio en la polaridad del sentimiento, donde la porción del texto que sigue a “pero” suele tener un mayor peso en la determinación del sentimiento general. Por ejemplo, en la frase “ChatGPT es genial, pero su conectividad es horrible”, se presenta un sentimiento mixto, pero la calificación global se ve influenciada principalmente por la connotación negativa de la segunda parte de la frase.
- **Análisis de trigramas para negación:** Esta regla se enfoca en los trigramas que preceden a un término con carga emocional, permitiendo identificar casi el 90 % de los casos donde la negación altera la polaridad del sentimiento. Un ejemplo claro se observa en frases con negación, como “ChatGPT no es realmente tan bueno”. En este caso, el análisis del trígama capta cómo la negación modifica la polaridad del sentimiento expresado, pasando de una aparente afirmación positiva a una connotación negativa.

Gracias a estas reglas, *VADER* alcanza una sensibilidad superior en la detección de expresiones sentimentales, acercándose a una interpretación más humana. Su habilidad para generalizar con efectividad, particularmente en el análisis de textos de *RRSS*, lo ubica en una posición ventajosa respecto a otros métodos. *VADER* no solo es eficaz en una amplia gama de dominios sino que también opera sin depender de grandes conjuntos de datos de entrenamiento, ofreciendo así una notable versatilidad. Además, se destaca por su facilidad de uso, lo cual lo hace accesible incluso para usuarios sin conocimientos técnicos especializados. *VADER* emplea un léxico validado por humanos, que asigna puntuaciones de polaridad

e intensidad a términos específicos, abarcando un espectro que va de lo negativo a lo positivo. Esta determinación de polaridad se basa en valores numéricos que varían de -1 a +1, asignando los valores más bajos a sentimientos negativos, los cercanos a cero a sentimientos neutros y los más altos a sentimientos positivos (Hutto y Gilbert, 2014). El proceso de análisis seguido en este *TFG* se centra en la generación de una puntuación compuesta para cada publicación de *X*, que refleje la valencia emocional global expresada en el mensaje. Esta puntuación compuesta se deriva de la suma de todas las puntuaciones individuales asignadas a cada palabra en la publicación, basadas en su polaridad e intensidad. Esta suma proporciona una indicación directa de la orientación emocional general del texto.

Este trabajo destaca la utilidad de *VADER* en la captura de las emociones manifestadas en los mensajes de los usuarios en las *RRSS*, brindando perspectivas enriquecedoras sobre la percepción pública hacia el uso de *ChatGPT*. La importancia de mantener ciertos aspectos del texto al aplicar *VADER* para el análisis de sentimientos radica en la sensibilidad única de este método, especialmente diseñado para textos provenientes de *RRSS* y otras fuentes web. *VADER* es sensible a elementos como los emoticonos, el uso de mayúsculas, la presencia de signos de puntuación y el contexto en el que se encuentran las palabras. Esto es fundamental, ya que en plataformas sociales como *X*, la forma en que se expresan las opiniones puede variar significativamente debido a la inclusión de emoticonos, jerga y la intensidad expresada mediante el uso de mayúsculas y signos de exclamación.

Por lo tanto, es importante destacar que la etapa de pre-procesamiento en el análisis de sentimientos con *VADER* se adapta para preservar características específicas del texto que aportan matices clave a la polaridad emocional. La omisión de estos elementos podría comprometer la exactitud del análisis. Por ejemplo, en el análisis de una publicación como: “¡¡La película es BUENÍSIMA!!”, un pre-procesamiento orientado al modelado de tópicos simplificaría esta expresión a: “película bueno”, lo cual resultaría en una puntuación de sentimiento reducida y no reflejaría fielmente la intensidad emocional original del mensaje (Bonta, Kumaresh, y Janardhan, 2019). La preservación de estos aspectos textuales es primordial para aprovechar la sensibilidad de *VADER* y garantizar la precisión en el análisis de sentimientos, evitando distorsiones en la interpretación de las emociones expresadas por los usuarios.

Capítulo 4

Resultados

El presente capítulo muestra los resultados obtenidos al implementar la metodología de análisis de datos descrita en el Capítulo 3. Como se ha explicado a lo largo de las secciones anteriores, el análisis se lleva a cabo sobre un conjunto de publicaciones de *X* que encuadran la temática de *ChatGPT* como tecnología disruptiva. Los apartados que suceden describen la preparación de los datos, el pre-procesamiento de los mismos, el análisis de *n-gramas*, el modelado de tópicos y el análisis de sentimientos sobre el conjunto de datos objeto de estudio. El código utilizado para desarrollar todos los procesos mencionados se encuentra a disposición pública en el repositorio: (Suárez García, 2024).

4.1. Adquisición y Preparación de los Datos

Como se detalla en el Capítulo 3, la transición de *Twitter* a *X* ha restringido el acceso libre y directo a la descarga de las publicaciones a través de su *API*. Ante esta situación, se procedió a la búsqueda en diversos repositorios con el objetivo de identificar una base de datos de *X* que fuera adecuada para el estudio propuesto. Los criterios utilizados para elegir esta base de datos tuvieron en cuenta el volumen de observaciones y la presencia de palabras clave relevantes al tema de interés. Además, la presencia de metadatos adicionales, como el número de *likes* o *hashtags*, fue valorada por su capacidad para potenciar el análisis descriptivo. Basándose en estos parámetros, se eligió un conjunto de datos compuesto por más de 500.000 publicaciones, que incluye variables relevantes para el estudio y otros atributos que enriquecen el análisis. En la Tabla 4.1 se presentan las variables contenidas en el conjunto de datos extraído del repositorio. Este conjunto de datos, denominado “500k ChatGPT-related Tweets Jan-Mar 2023”, se encuentra disponible a través del citado repositorio (Khalid Ansari, 2023). La calidad de este conjunto de datos para el trabajo se confirmó al observarse que está centrado explícitamente en *ChatGPT*, incluyendo términos clave como “chatgpt” y “gpt”, así como *hashtags* y menciones relevantes asociadas con el modelo de *IA* conversacional de *OpenAI*, confirmando así su relevancia para el análisis propuesto.

Tabla 4.1: Variable contenidas en el dataset seleccionado

Nombre de la variable	Significado	Tipo de variable
date	Fecha de publicación	Caracter
id	Identificador único de la publicación	Caracter
content	Contenido de la publicación	Caracter
username	Nombre del usuario de la publicación	Caracter
like_count	Cantidad de “Me gusta” recibidos	Entero
retweet_count	Cantidad de <i>retweets</i> recibidos	Entero

Dado que el conjunto de datos se obtuvo de un repositorio, resulta relevante proceder a un proceso de limpieza antes de comenzar cualquier análisis. Este proceso garantiza que el conjunto de datos se ajuste de manera precisa a los requerimientos específicos del estudio. Se hizo uso de todas las variables incluidas en el conjunto de datos, garantizando así el aprovechamiento de toda la información disponible. No obstante, se llevaron a cabo los ajustes necesarios para determinar el tipo adecuado de variable. De forma paralela, se extrajeron los *hashtags* y las menciones de cada uno de los posts, enriqueciendo el conjunto de datos con estas variables adicionales. Esta información permite profundizar en el análisis, así como explorar dinámicas de interacción y temas de interés dentro de la comunidad. Además, se realizó un análisis de la longitud de las publicaciones, lo cual es instrumental para comprender patrones de comunicación y la densidad informativa de las publicaciones. Posteriormente, se procedió a identificar el idioma de cada publicación, una medida que facilita el análisis contextualizado y asegura la coherencia del estudio. También se realizaron ajustes en los nombres de las variables para simplificar su manejo durante el proceso de análisis. Como resultado, la Tabla 4.2 presenta el conjunto de datos final que se empleará en este proyecto, reflejando así un esfuerzo por asegurar la calidad y relevancia de los datos utilizados para el análisis propuesto.

Tabla 4.2: Variable contenidas en el dataset seleccionado

Nombre de la variable	Significado	Tipo de variable
id	Identificador único de la publicación	Caracter
text	Contenido de la publicación	Caracter
user	Nombre del usuario de la publicación	Caracter
fecha	Fecha de publicación	Fecha
día	Día del mes de publicación	Entero
mes	Mes de publicación	Entero
like_count	Cantidad de “Me gusta” recibidos	Entero
retweet_count	Cantidad de <i>retweets</i> recibidos	Entero
hashtags	<i>Hashtags</i> contenidos en la publicación	Caracter
mentions	Menciones contenidos en la publicación	Caracter
idioma	Idioma de la publicación	Caracter
longitud	Cantidad de caracteres de la publicación	Entero

Partiendo de estos elementos, se desarrolló un análisis descriptivo preliminar del conjunto de datos, comenzando con una evaluación del volumen de registros a lo largo del tiempo, como muestra la Figura 4.1. Esta figura representa la frecuencia diaria de publicaciones desde el 4 de enero hasta el 29 de marzo de 2023, periodo durante el cual se observa un incremento en la actividad, resultado acorde con las tendencias discutidas en el Capítulo 1 sobre el crecimiento en el número de usuarios y las búsquedas de *ChatGPT* en *Google*. Visualmente, se distinguen dos picos significativos de actividad. El primero el 7 de febrero, coincidente con el anuncio de *Bard* por *Google*, un *chatbot* de *IA* identificado como competidor de *ChatGPT*; y, la integración de *IA* en su motor de búsqueda para simplificar información compleja, facilitando el entendimiento de los usuarios. Todas estas acciones se entienden como una respuesta de *Microsoft* al éxito de *ChatGPT* de *OpenAI* (Forbes, 2023). Al día siguiente, 8 de febrero de 2023, ocurre otro evento clave, la presentación por *Microsoft* de nuevas versiones de *Bing* y *Edge*, potenciadas por la tecnología GPT de *OpenAI*. La versión preliminar de *Bing* se lanzó ese día, acompañada de la promesa de una versión móvil y la integración de capacidades de chat basadas en *IA* en todos los navegadores (Europa Press, 2023). El segundo pico, aún más notable, ocurre el 15 de marzo cuando *OpenAI* lanzó *GPT-4*, conocido por su rendimiento humano en tareas profesionales y académicas, así como por su capacidad para procesar instrucciones complejas. Introdujo un modelo multimodal capaz de manejar texto e imágenes, marcando una evolución para la empresa hacia mayor seguridad y precisión tras un entrenamiento con datos variados. Además, *GPT-4* mejora la neutralidad política y minimiza diversos sesgos de versiones previas. En este hito se refleja, a su vez, la colaboración entre *OpenAI* y *Microsoft*, ya que *GPT-4* se presentó disponible exclusivamente a través de *ChatGPT Plus* y en una versión de prueba en el motor de búsqueda *Bing* (BBC, 2023).

La Figura 4.2 muestra la frecuencia acumulada de publicaciones por cada día de la semana, revelando una tendencia notable: la actividad disminuye significativamente durante los fines de semana (sábado y domingo) en comparación con los días laborables. Este patrón sugiere que la interacción y el intercambio de contenido relacionado con *ChatGPT* experimentan una variación semanal, probablemente influenciada por los ciclos laborales y de descanso de la comunidad. Durante los fines de semana, podría presentarse una disminución en las discusiones técnicas o en los debates profundos sobre *ChatGPT*, posiblemente debido a que los profesionales del tema están menos activos en estos días. Por el contrario, los días laborables presentan un incremento en la actividad, reflejando un mayor compromiso de la comunidad profesional y académica en la plataforma, lo cual podría potenciar también el intercambio de ideas y la generación de contenido de mayor profundidad técnica.

El análisis de distribución de longitud de las publicaciones proporciona una visión detallada del tipo de contenido compartido en las *RRSS* respecto a *ChatGPT*. La longitud de una publicación puede ofrecer indicios sobre la profundidad y la complejidad del mensaje, así como sobre el esfuerzo invertido en su creación. La Tabla 4.3 categoriza las publicaciones según su longitud, revelando que la mayoría de los posts son cortos, con más del 50 %

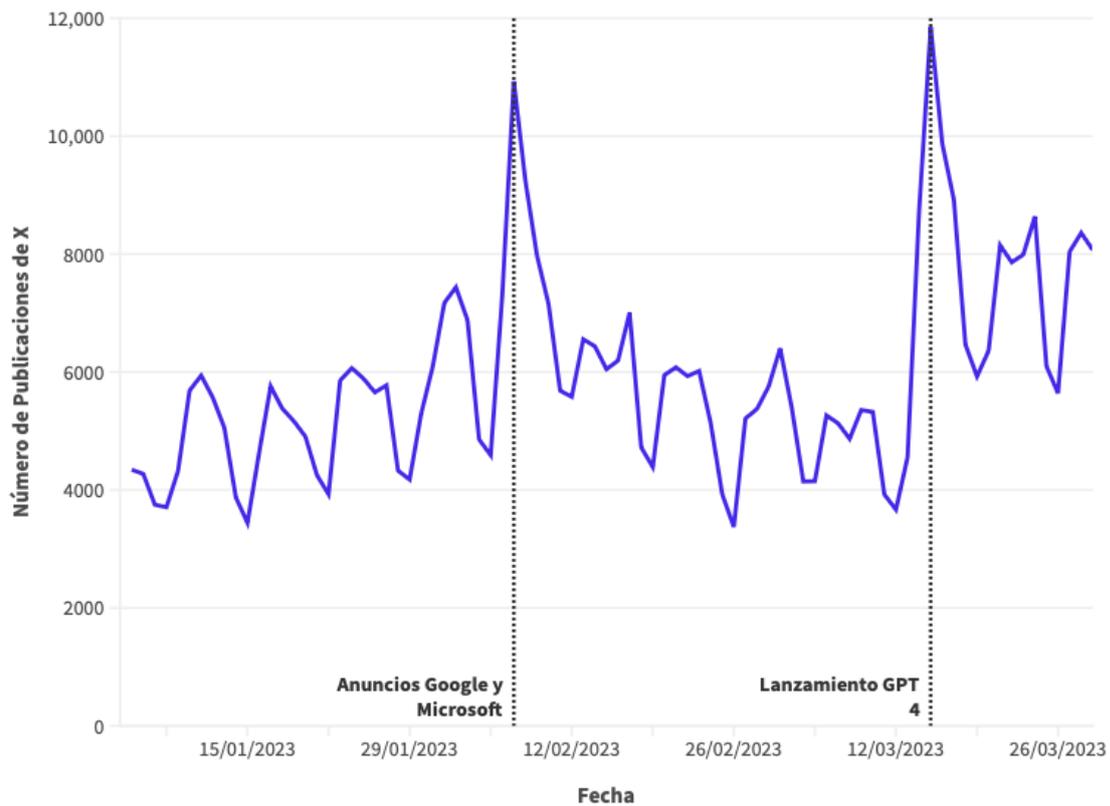


Figura 4.1: Análisis Temporal: Frecuencia Diaria de Publicaciones de X. Elaboración propia

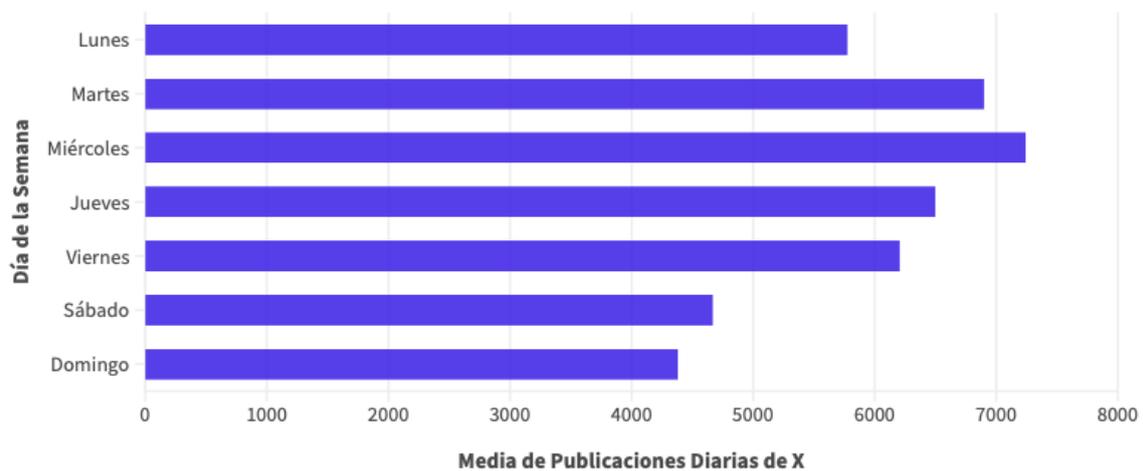


Figura 4.2: Análisis Temporal: Frecuencia Semanal de Publicaciones de X. Elaboración propia

de ellos conteniendo menos de 200 caracteres. Esta tendencia sugiere una preferencia por la brevedad y la rapidez en la comunicación sobre *ChatGPT* en las *RRSS*. Además, aquellos posts que exceden los 280 caracteres, lo que implica la creación de hilos para desarrollar ideas más complejas, constituyen aproximadamente el 3% del total. Esta observación indica

que, aunque la mayoría de las interacciones son concisas, existe una minoría significativa de usuarios dispuestos a profundizar en discusiones más detalladas o a compartir reflexiones extensas sobre *ChatGPT*, posiblemente en forma de análisis, opiniones fundamentadas o debates técnicos.

Tabla 4.3: Distribución de Longitudes de Publicaciones

Longitud	Número de Publicaciones	% sobre el Total
0 a 100	138.340	27.67 %
101 a 200	170.755	34.15 %
201 a 300	174.423	34.88 %
301 a 1000	16.518	3.30 %

El objetivo del estudio de los idiomas presentes en las publicaciones de X es entender la diversidad lingüística y los patrones de comunicación en la plataforma respecto a *ChatGPT*. Para determinar el idioma de cada publicación, se utilizó el método de categorización de textos basado en *n-gramas*, implementado por el paquete *textcat* en *RStudio* (Hornik, Rauch, y Christian Buchta, 2023). Este paquete dispone de una amplia colección de perfiles de *n-gramas*, cubriendo hasta 74 idiomas distintos. La metodología empleada por el algoritmo consiste en analizar la frecuencia de secuencias de caracteres específicas en los textos, elaborando perfiles de *n-gramas* para cada idioma. Al clasificar un nuevo texto, el algoritmo compara su perfil de *n-gramas* con los perfiles existentes en su base de datos, asignando el idioma del texto basado en la mejor correspondencia encontrada. A través de este método, se logró identificar la presencia de 49 idiomas diferentes dentro del corpus analizado. Este hallazgo destaca la variedad lingüística de las discusiones en torno a *ChatGPT*. La Figura 4.3 muestra los 20 idiomas más detectados entre las publicaciones. Se encuentra que el inglés es el idioma más prevalente en las publicaciones de X , con un total de 380.041 ocurrencias, representando más del 75 % de las publicaciones. Esto refleja la predominancia global del inglés como idioma de comunicación en línea. Le sigue el escocés, con 47.879 ocurrencias, y el frisón medio, con 18.629 ocurrencias, representando una presencia significativa de otros idiomas europeos en la plataforma. Sin embargo, el espectro lingüístico se extiende más allá, incluyendo idiomas como el alemán, el catalán y el danés, todos ellos con una presencia significativa. Igualmente, se identifican idiomas menos habituales como el manés, el latín, el indonesio y el eslovaco, reflejando así una gran diversidad lingüística y un interés global en el tema de estudio. Tras este examen lingüístico, se optó por conservar únicamente aquellos posts en inglés y lenguas cercanas, para los cuales los diccionarios de inglés son aplicables. De esta manera, se seleccionaron idiomas como el inglés, escocés, frisón medio, frisón, gaélico escocés, bretón, manés, irlandés y galés. Esta decisión resultó en un corpus refinado de 459.699 registros que serán analizados en etapas subsecuentes, garantizando así un enfoque coherente con la disponibilidad de herramientas lingüísticas.

Por otra parte, los emoticonos o *emojis* son habituales en *RRSS* ya que enriquecen la

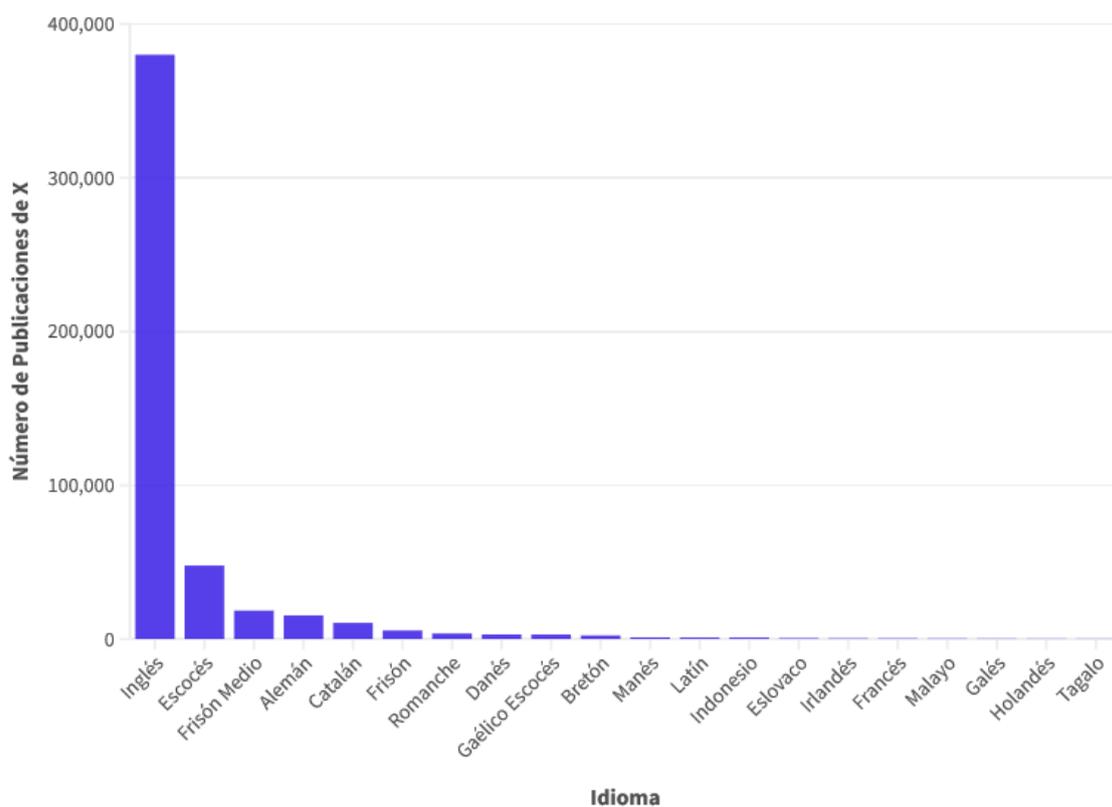


Figura 4.3: Análisis Lingüístico: Principales Idiomas Identificados en las Publicaciones de X. Elaboración propia

expresividad de las publicaciones y potencian la intensidad emocional de los mensajes. La Figura 4.4 ilustra los 20 emoticonos más populares en las publicaciones, destacando su frecuencia de uso. Entre ellos, predominan las expresiones faciales que denotan emociones positivas, como la risa y la alegría, apuntando a un tono generalmente optimista en el diálogo sobre *ChatGPT*. Además, se observa una notable presencia de símbolos como el fuego y el cohete, que sugieren entusiasmo y la idea de avance, pudiendo estar vinculado a conversaciones sobre innovaciones o éxitos en tecnología. Por otro lado, ciertos emoticonos reflejan pensamiento crítico o incertidumbre, insinuando debates o cuestionamientos en torno a la temática; mientras que otros, como el emoji llorando, podrían interpretarse como indicativos de aspectos negativos relacionados con *ChatGPT*.

Los *hashtags* funcionan como etiquetas temáticas que categorizan el contenido, simplifican la búsqueda y hallazgo de información en las plataformas. Estas etiquetas son instrumentos significativos para analizar tendencias y captar opiniones en la comunidad online. Permiten a los usuarios mantenerse informados sobre áreas específicas de interés y participar activamente en diálogos relevantes (Caleffi, 2015). La evaluación de los 20 *hashtags* más utilizados, mostrados en la Figura 4.5, revela las corrientes predominantes en las conversaciones online, destacando un marcado interés por temas relacionados con la innovación y

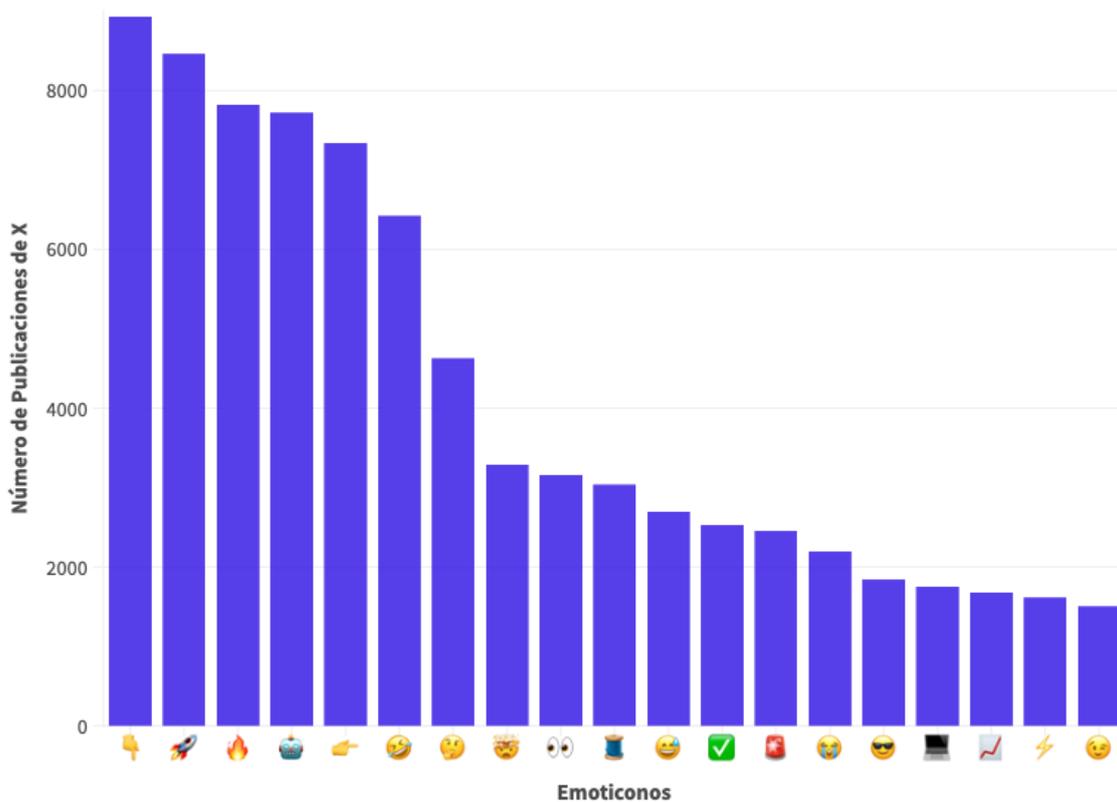


Figura 4.4: Análisis de Emoticonos: Principales *Emojis* Identificados en las Publicaciones de X. Elaboración propia

la tecnología, tales como #AI, #ArtificialIntelligence, #MachineLearning y #technology. Se sugiere un fuerte interés en temas de vanguardia como la IA, el ML y los avances tecnológicos en general. Además, se observa una presencia significativa de *hashtags* asociados con empresas y organizaciones líderes en el campo tecnológico, como #OpenAI, #Google y #Microsoft. Esto indica un interés generalizado en las actividades, proyectos y productos de estas empresas, así como en las noticias y desarrollos recientes relacionados con ellas. También se encuentran *hashtags* relacionados con tendencias emergentes, como #NFT y #Crypto, que reflejan el creciente interés en el mundo de las criptomonedas y los activos digitales no fungibles (NFT). El análisis preliminar indica un incremento en la actividad online coincidiendo con hitos importantes en el sector de la IA y la tecnología, tales como los lanzamientos de GPT-4 y Bard, representados por los *hashtags* #GPT4 y #Bard. La relación entre eventos del mundo real y el dinamismo en las RRSS destaca la importancia de los *hashtags* como indicadores de temas relevantes en las plataformas.

El análisis descriptivo del conjunto de datos de X sobre ChatGPT revela momentos clave, patrones estacionales, diversidad lingüística y emocional, así como intereses temáticos, destacando la dinámica y la amplitud de la comunidad. Se han destacado momentos relevantes que generan un incremento de la actividad de la plataforma, tales como el lanzamiento de

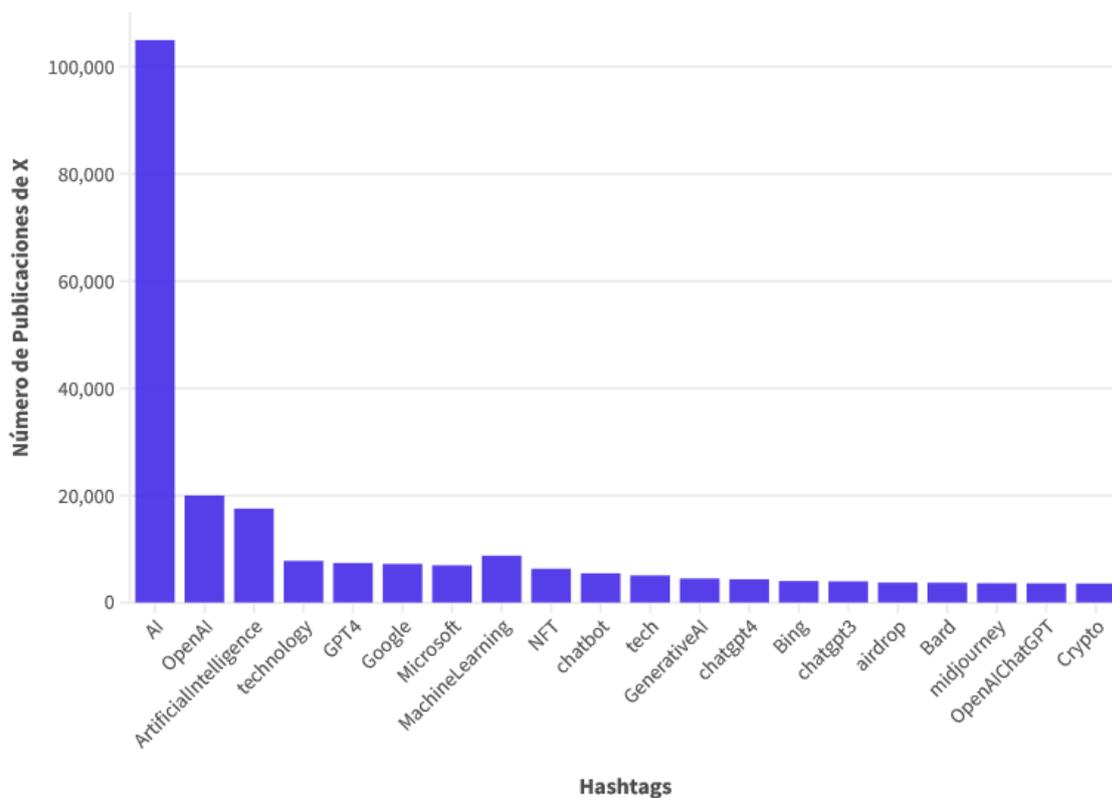


Figura 4.5: Análisis de los Principales *hashtags* Presentes en las Publicaciones de X.
Elaboración propia

GPT-4 y *Bard*, señalando la importancia de estos eventos en la movilización de la comunidad online. Además, se observa un patrón estacional en la participación de los usuarios, evidenciado por una reducción de actividad durante los fines de semana. La longitud de las publicaciones muestra una amplia variedad, donde predominan las publicaciones cortas, aunque también se observan hilos de conversación. Esto sugiere la disposición de los usuarios para participar en diálogos más elaborados y detallados. La diversidad de idiomas dentro del dataset subraya la amplitud y el alcance global de la discusión en torno a *ChatGPT*, reflejando la penetración internacional de esta tecnología. Los emoticonos utilizados en las publicaciones manifiestan un amplio espectro de emociones, desde el entusiasmo hasta la reflexión crítica, proporcionando una dimensión adicional al análisis emocional de las interacciones. Por último, los *hashtags* empleados resaltan un enfoque en temas relacionados con la tecnología, la innovación y acontecimientos significativos en el ámbito de la *IA*. Este análisis resalta los intereses predominantes y los aspectos que suscitan mayor interés dentro de la comunidad a la hora de hablar sobre *ChatGPT*.

4.2. Pre-procesamiento de los Datos

Tras realizar este análisis preliminar de los datos para comprender su estructura y organización, se avanzó hacia una etapa de preprocesamiento con el fin de simplificar el contenido textual de las publicaciones. Este procedimiento facilita el análisis de los datos en las etapas posteriores de modelado de tópicos y análisis de sentimientos. Este proceso de limpieza y normalización del corpus textual se diseñó para asegurar la calidad y la coherencia de los datos, alineándose con las estrategias metodológicas detalladas en el Capítulo 3.

Inicialmente, se desarrolló una función de limpieza para tratar distintos componentes del texto, tales como enlaces web, caracteres especiales, números, signos de puntuación y letras sueltas que carecen de valor semántico. Este proceso incluyó la normalización mediante la conversión del texto a minúsculas y la eliminación de acentos para asegurar la mayor uniformidad posible. Posteriormente, se eliminaron las *stopwords* y términos presumiblemente irrelevantes para el análisis, como “chatgpt”, “chat”, y “gpt”, considerando su presencia constante en el contexto de estudio. La fase siguiente consistió en la lematización, aprovechando técnicas de *NPL* para reducir las palabras a su forma base y facilitar el análisis al agrupar variantes de un mismo término. Finalmente, se llevaron a cabo modificaciones para eliminar filas con valores faltantes y duplicados en el conjunto de datos procesado, asegurando la calidad y consistencia de los datos para su análisis posterior. Seguidamente, se revisa el proceso de eliminación de *stopwords* y de lematización de manera iterativa, garantizando así la máxima calidad del corpus. Se realizaron correcciones manuales en aquellas palabras con alta frecuencia y errores en su procesamiento. Esto se hizo para abordar situaciones donde la biblioteca utilizada no lograba identificar o lematizar correctamente las palabras en inglés. Este refinamiento manual permitió una mejora significativa en la precisión al agrupar términos relacionados, elevando así la calidad del conjunto de datos y optimizando la extracción de información.

Posteriormente, se procedió a visualizar las palabras más frecuentes en el corpus mediante la creación de una nube de palabras o *Wordcloud*. Esta técnica permite identificar visualmente las palabras más frecuentes en el corpus, proporcionando, de forma preliminar, una rápida comprensión de los conceptos más relevantes. La nube de palabras (ver Figura 4.6) presenta los términos clave del corpus, basándose en su frecuencia. Palabras como “new” y “use” sugieren un enfoque en la innovación y la aplicación práctica de *ChatGPT*, mientras que términos como “ask”, “write”, “create” y “answer” indican las funcionalidades comunicativas y creativas que los usuarios asocian con esta tecnología. “Good”, “think” y “tool” reflejan evaluaciones positivas, reflexiones y la consideración de *ChatGPT* como un recurso útil. Se destacan también términos como “technology” y “future”, lo que sugiere un enfoque en las innovaciones tecnológicas y las tendencias futuras. “People” y “human”, por su parte, sugieren un interés en la interacción social y la relevancia humana en el contexto tecnológico. Finalmente, términos como “model”, “language” y “tool” revelan la importancia de las he-

del proceso, que sirven como fundamento para determinar la relevancia de cada término dentro del conjunto de datos. En este contexto, se destacan los 30 *n-gramas* más relevantes de cada categoría, seleccionados por su destacada puntuación en la métrica *TF-IDF*, revelando así su significativa contribución al corpus analizado.

4.3.1. Análisis de Unigramas

El término “unigrama” se refiere a una palabra individual. Las 30 palabras más relevantes dentro del corpus, basadas en la métrica *TF-IDF*, se encuentran representadas en la Figura 4.7. Los datos revelan una variedad de acciones verbales y términos relacionados con la interacción humana y la tecnología, lo cual es coherente con la temática central del corpus, *ChatGPT*. Términos como “use”, “ask”, “like”, “write”, y “think”, indican actividades o acciones frecuentemente asociadas con la utilización o discusión de tecnologías de *IA*. Por otro lado, términos como “new”, “tool”, “good”, “know”, y “work” resaltan la percepción y evaluación de la tecnología, sugiriendo un enfoque en la innovación, la utilidad, la calidad, el conocimiento y la eficacia. Además, palabras como “time”, “thank”, “answer”, “create”, y “question” sugieren una dinámica de intercambio y agradecimiento, posiblemente reflejando las interacciones de los usuarios con *ChatGPT*. Finalmente, unigramas como “learn”, “great”, “need”, “help”, y “way” podrían estar indicando el interés en el aprendizaje, la satisfacción, la búsqueda de asistencia y la exploración de métodos o enfoques nuevos. Este análisis de los unigramas más relevantes ofrece una idea general de las principales áreas de interés en la comunidad en línea respecto a *ChatGPT*,

4.3.2. Análisis de Bigramas

Un bigrama es una secuencia de dos palabras consecutivas en un texto. Estas secuencias pueden ser significativas porque capturan relaciones y asociaciones entre palabras que pueden no ser evidentes al considerarlas de manera individual o como unigramas. Analizar los bigramas adquiere su importancia al permitir examinar cómo ciertas palabras tienden a aparecer juntas en el texto, proporcionando información sobre patrones lingüísticos, temas recurrentes, términos técnicos o estructuras gramaticales específicas.

La Figura 4.8 representa los 30 bigramas más relevantes del corpus acompañados de sus respectivas puntuaciones *TF-IDF*. La aparición frecuente de “artificial intelligence” y “language model” destaca el enfoque en la *IA* y los modelos de lenguaje al hablar sobre *ChatGPT* en *RRSS*. La combinación de términos como “ask write” y “ask question” continúan mostrando el uso interactivo que se le da a la herramienta, pero además, también se observa un énfasis en la generación de contenido, como se muestra en “write poem” y “write code”, ampliando así los usos encontrados en los unigramas. Por otra parte, se observa la presencia de diferentes tecnologías y herramientas como “search engine” o “new tool”, acompañados de personali-

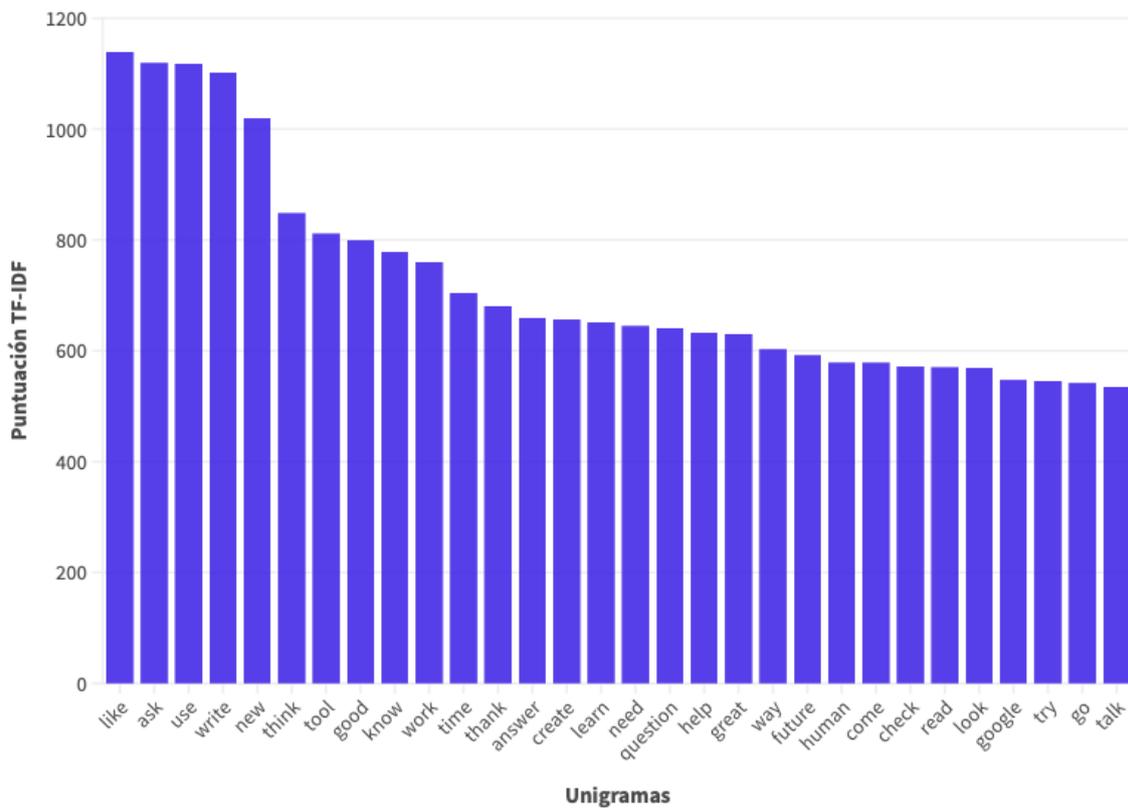


Figura 4.7: 30 Unigramas de Mayor Relevancia en el Corpus. Elaboración propia

dades y empresas relevantes como “google search” o “elon musk”. Además, la aparición de términos como “game changer” y “mind blow” indica un reconocimiento hacia los significativos avances que están ocurriendo en el ámbito de la IA, marcando un entusiasmo y una valoración positiva hacia las innovaciones tecnológicas.

4.3.3. Análisis de Trigramas

Un trigrama, que consiste en una secuencia de tres palabras consecutivas en un texto, amplía la comprensión de las relaciones y asociaciones entre términos al analizar tríos de palabras. Al incorporar un término adicional en comparación con los bigramas, los trigramas ofrecen una visión más detallada de las conexiones lingüísticas, permitiendo una comprensión más completa de las estructuras sintácticas y semánticas presentes en el discurso. Este análisis se convierte especialmente relevante en contextos donde la interpretación de las relaciones entre palabras puede revelar tendencias temáticas más complejas. Al examinar trigramas, se pueden identificar frases o expresiones idiomáticas específicas, así como secuencias de palabras que, juntas, forman conceptos o ideas que no serían evidentes al analizar los términos de manera aislada.

A través de la Figura 4.9 se destacan los 30 trigramas con las puntuaciones *TF-IDF* más

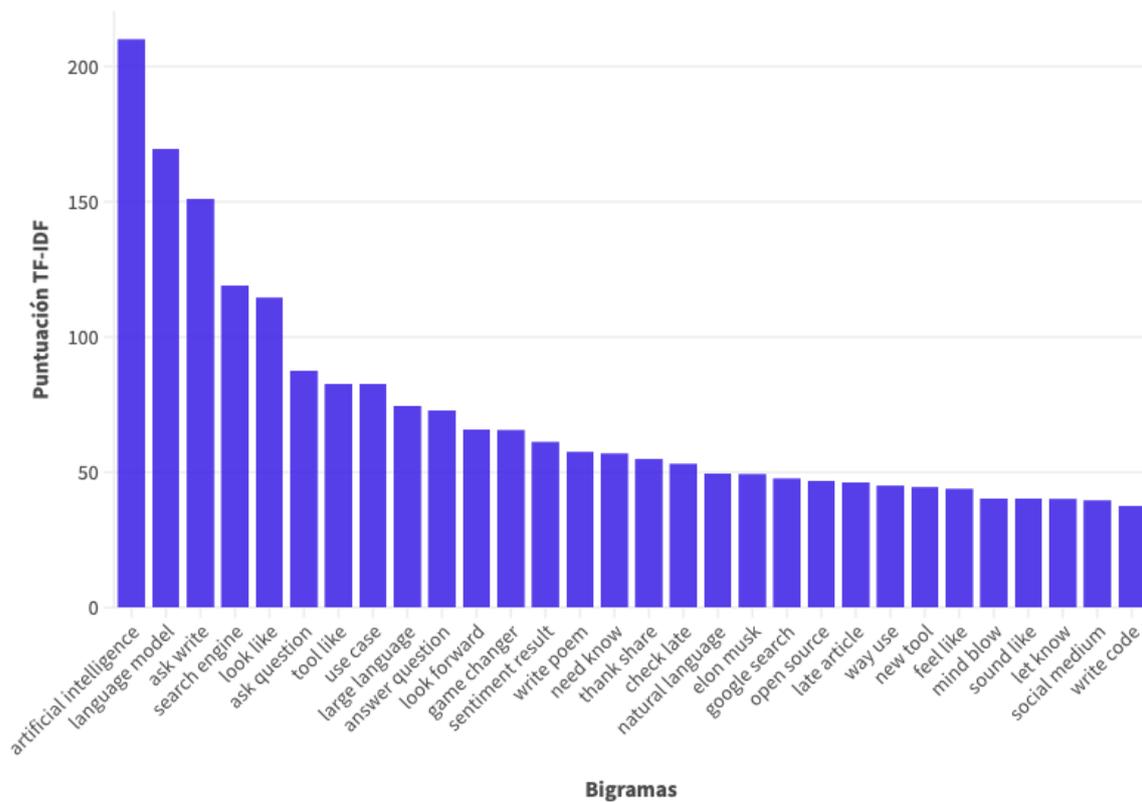


Figura 4.8: 30 Bigramas de Mayor Relevancia en el Corpus. Elaboración propia

elevadas del corpus, consolidando las observaciones hechas a partir de los análisis de bigramas y unigramas. Se evidencia un fuerte interés en aspectos técnicos y capacidades de *ChatGPT*, como demuestran términos tales como “large language model” y “natural language processing”. Igualmente, expresiones como “ask write poem” y “ask write song” ilustran la utilización de *ChatGPT* para la generación creativa de contenido. Además, frases que incluyen “sentiment result positive”, “sentiment result neutral”, y “sentiment result negative” reflejan la aplicación de *ChatGPT* en el análisis de emociones y opiniones. El corpus también revela una interacción con motores de búsqueda en línea, como se indica en “bing search engine” y “google search engine”, resaltando la búsqueda de información por parte de los usuarios. Además, se introducen términos relativos a los intereses y pagos como “pay interest free” o “interest free instalment”, que podrían hacer referencia a las condiciones económicas de acceso a esta tecnología de IA. En este contexto, los trigramas muestran la forma en la que la IA, particularmente *ChatGPT*, continúa expandiéndose a través de una gama más amplia de campos, evidenciando su creciente influencia y aplicabilidad en múltiples aspectos de la vida y el trabajo cotidianos.

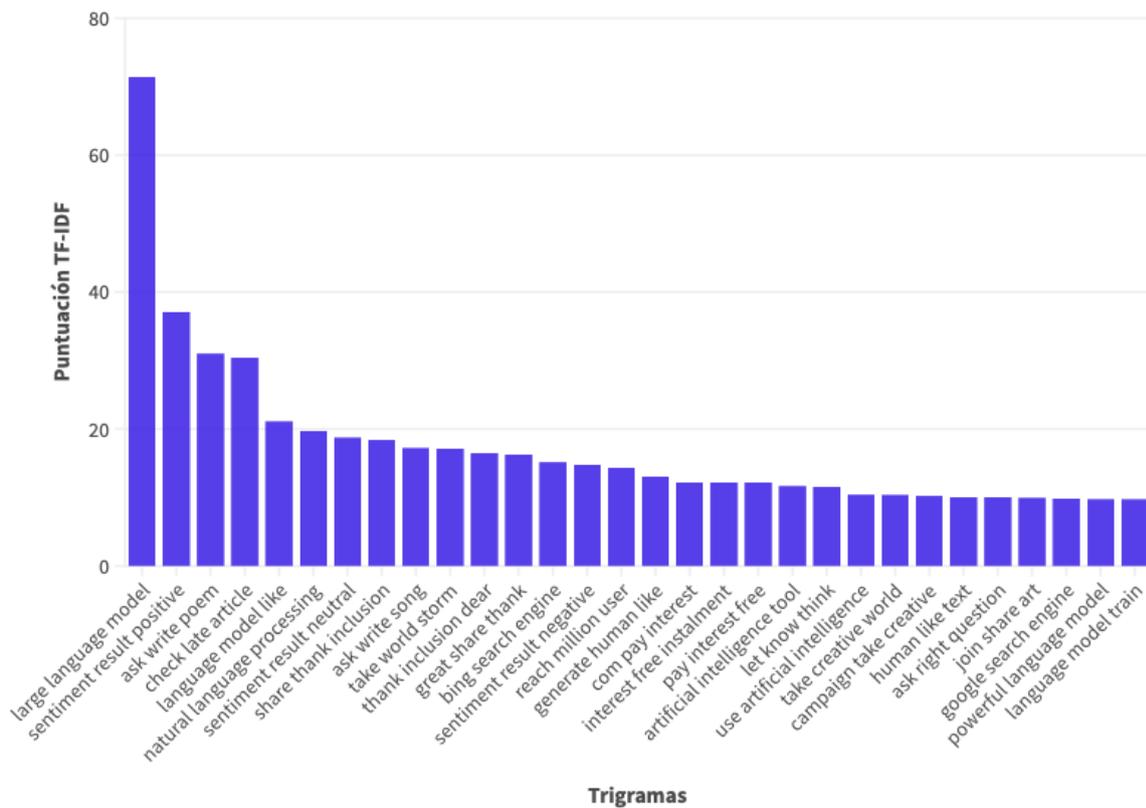


Figura 4.9: 30 Trigramas de Mayor Relevancia en el Corpus. Elaboración propia

4.4. Modelado de Tópicos

El modelado de tópicos es una técnica utilizada en el *NPL* para identificar y clasificar los temas principales presentes en un conjunto de documentos o corpus de texto. Este método se centra en identificar agrupaciones de palabras que tienden a aparecer juntas con alta probabilidad dentro del corpus, sugiriendo la existencia de temas específicos. Para el presente trabajo, se ha seleccionado *LDA* como la técnica para realizar el modelado de tópicos. *LDA* se considera un modelo generativo que opera bajo la premisa de que cada documento en el corpus se compone de una mezcla de diversos tópicos, y que cada tópico se distingue por una distribución particular de palabras. A través del análisis de las apariciones y la frecuencia de las palabras, se agrupan en clústeres que son semánticamente coherentes y representativos de los diferentes tópicos identificados en el corpus. Este procedimiento permite no solo descubrir la estructura temática subyacente del conjunto de documentos sino también proporcionar una comprensión más detallada del contexto asociado al corpus procesado.

Para identificar el número óptimo de tópicos en el modelado, se implementó un análisis compuesto por dos etapas: la evaluación de la coherencia de tópicos y la visualización de la distancia intertópica. En primer lugar, se empleó una métrica de coherencia para evaluar la calidad de los tópicos generados considerando diversos valores para el número de tópicos.

Esta métrica mide la interpretabilidad y la cohesión semántica de los tópicos formulados, estableciendo que una mayor coherencia se traduce en tópicos más claros y consistentes. Siguiendo la metodología expuesta en el Capítulo 3, se computaron valores de coherencia para un espectro de tópicos que variaba de 2 a 12 categorías. Tras calcular los valores de coherencia para cada configuración de tópicos, los resultados fueron visualizados en la Figura 4.10. Basándose en estos datos, el número óptimo de tópicos (valor k) se identificó donde la métrica de coherencia registró su máximo, optándose por cinco tópicos para el modelado. Así, este análisis mostró que el nivel máximo de coherencia se alcanzó con cinco tópicos, obteniéndose un índice de coherencia de 0.474261. Este resultado sugiere la presencia de cinco áreas temáticas diferenciadas dentro del corpus, cada una caracterizada por agrupaciones de palabras estrechamente relacionadas semánticamente y claramente diferenciadas entre los cinco tópicos.

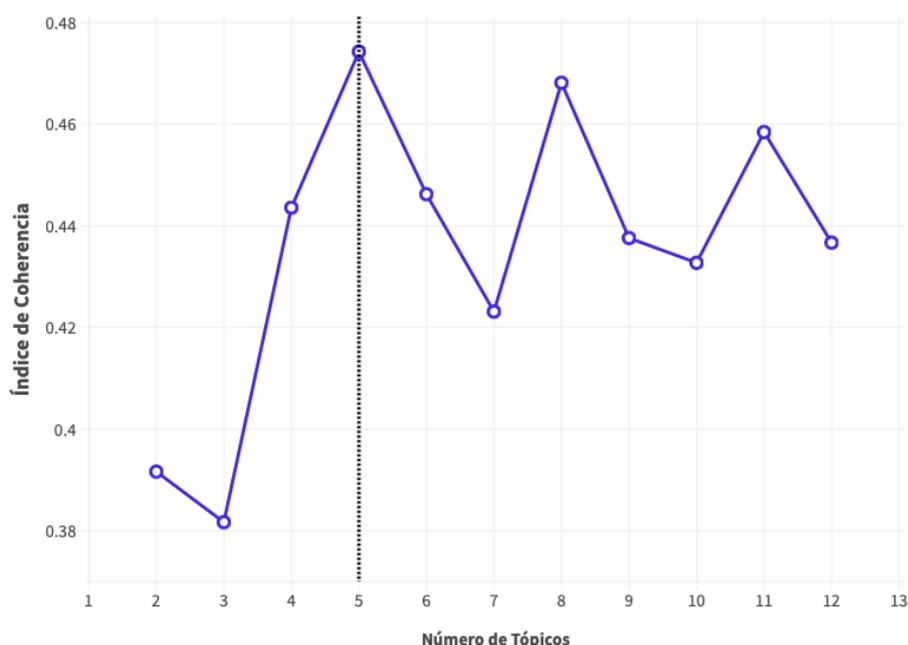


Figura 4.10: Índice de coherencia por número de tópicos. Elaboración propia

En segundo lugar, se hace uso de la visualización intertópica para verificar la estructura y la separación existente entre los tópicos identificados. Esta visualización proporciona una representación gráfica de la relación entre los tópicos en un espacio bidimensional, tal y como se muestra en la Figura 4.11, generada con el paquete *pyLDavis*. Esta herramienta gráfica facilita la identificación de las similitudes y diferencias entre los tópicos, contribuyendo a verificar la precisión con la que han sido definidos y su distinción mutua. La visualización confirma la existencia de una demarcación clara entre los tópicos, corroborando la adecuada identificación del número óptimo de tópicos (k). Este resultado permitirá lograr una alta interpretabilidad de las categorías identificadas, facilitando un análisis posterior más detallado

y preciso.

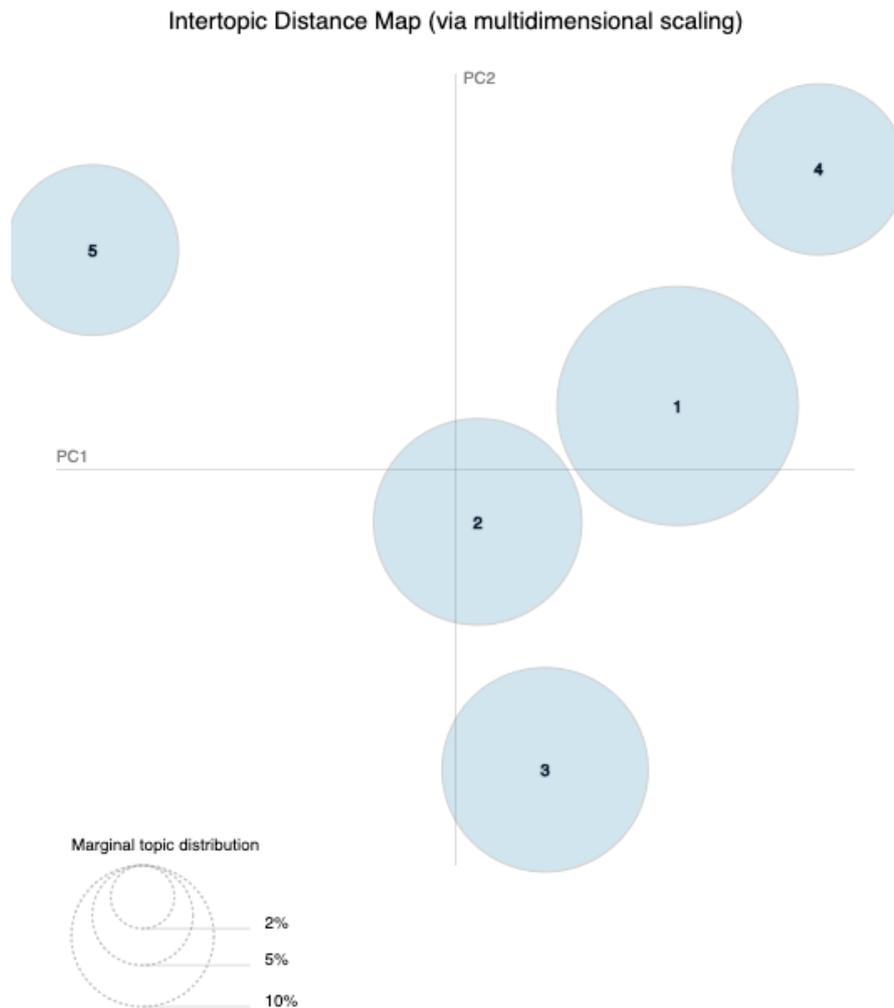


Figura 4.11: Mapa de Distancia Intertópica para $k = 5$. Elaboración propia

La Tabla 4.4 presenta los resultados del modelado de tópicos aplicado al corpus. Esta proporciona una descripción de las palabras clave, bigramas y trigramas más relevantes asociados con cada tópico. A través de estos resultados, se facilita la identificación de las principales temáticas exploradas en el corpus y la atribución de categorías distintivas a cada tópico.

El primer tópico, **Grandes Inversiones y Desarrollos en el Campo Tecnológico**, se enfoca en las últimas noticias y avances tecnológicos vinculados a los motores de búsqueda y la IA (“*search engine*” y “*artificial intelligence*”). Se exploran las inversiones realizadas en este sector, las cuales fomentan constantemente la creación de productos innovadores. En este sentido, se destacan empresas líderes en tecnología como *Google*, *Microsoft* y *Bing*. Asimismo, se resalta a *Bard* como un modelo en competencia con *ChatGPT*, concepto que ya se había destacado previamente en este estudio. Paralelamente, se resalta el papel de *OpenAI*

como desarrollador de *ChatGPT* y la influencia que ejerce en el sector. Estas empresas han realizado históricamente inversiones multimillonarias en tecnología (“*invest billion creator*”, “*multibillion dollar investment*”), lo que ha permitido el desarrollo de productos innovadores como *Google Search* y *Microsoft Bing*, alcanzando así millones de usuarios en todo el mundo (“*million user*”). A día de hoy, estas empresas continúan realizando tales inversiones, acto que refleja su compromiso por mantenerse como líderes en el mercado. El continuo lanzamiento (“*launch*”) de productos innovadores asegura su posición como creadores y desarrolladores de tecnología de vanguardia.

El segundo tópico se cataloga como **Interés y Proyecciones Futuras en IA** (“*future artificial intelligence*”). En esta categoría, se destaca el valor que la sociedad atribuye a los avances de la IA, reflexionando sobre su impacto en diversos aspectos de la existencia y la interacción humana. Este tópico permite analizar la relevancia de aprender de estos avances y utilizarlos de manera efectiva para impulsar el progreso en áreas como la educación, donde la IA tiene el potencial de transformar la forma en que se enseña y se aprende (“*learn*” y “*use*”). En este contexto, los modelos de lenguaje se han convertido en una herramienta indispensable para investigadores y profesionales que trabajan en el campo de la IA. Estos modelos están revolucionando el mundo (“*take world storm*”) y abriendo nuevas posibilidades y desafíos en áreas como la comprensión del lenguaje natural y la generación de contenido.

A continuación, el tercer tópico, **Innovación en el Procesamiento de Lenguaje**, destaca los avances relacionados con los grandes modelos de lenguaje (“*large language model*”). La inclusión de estos modelos en discusiones en *RRSS* es relevante, pues refleja su capacidad para transformar las interacciones humanas con la tecnología. Adicionalmente, se percibe un creciente interés por su impacto transformador, que promete influir positivamente en una amplia gama de sectores, desde la medicina hasta la educación. Este tópico también destaca el interés y la expectativa, los expertos están anticipando una evolución continua en estos modelos, con mejoras significativas en su capacidad para abordar desafíos cada vez más complejos, como la comprensión del contexto y la generación de texto coherente y relevante. Estos avances abren nuevas puertas para la creación de contenido y la comunicación (“*important step journey*” y “*cut edge technology*”).

El cuarto tópico, por su parte, se define como **Aplicaciones Prácticas de Modelos de Lenguaje**, donde se discute la formulación de preguntas y la creación de contenido literario, musical y recursos de codificación utilizando modelos de lenguaje avanzados (“*ask question*”, “*answer question*”, “*write poem*”, “*write code*”). En esta categoría, los usuarios exponen la capacidad de estos modelos para generar respuestas precisas y coherentes, así como para crear textos poéticos, narrativos o canciones de manera automatizada. Se observa también un interés activo por parte de los usuarios en explotar estos modelos para resolver desafíos prácticos en campos como la educación, donde se utilizan para evaluaciones académicas y la creación de material didáctico innovador. Además, en el sector del marketing, estos modelos se emplean para desarrollar estrategias publicitarias creativas que conecten de

manera efectiva con el público objetivo (“*campaign take creative*” y “*take creative world*”). Es importante destacar que aunque estas herramientas ofrecen oportunidades revolucionarias, su uso conlleva una serie de consideraciones éticas y de seguridad que deben ser abordadas adecuadamente.

Finalmente, el quinto tópico trata estas preocupaciones, categorizándose como **Creación de Contenido y Consideraciones Éticas** en relación con los grandes modelos de lenguaje como *ChatGPT*. En esta categoría, los usuarios expresan sus percepciones acerca del contenido generado por estas herramientas, evaluando su calidad y señalando posibles defectos, incluidos los sesgos políticos o éticos que podrían servir para distinguir entre el texto producido por humanos y el generado por *IA* (*political bias*, *detect generate text* y *human like text*). En este contexto, también se aborda la influencia y las aportaciones de figuras relevantes en la tecnología, como Elon Musk y Sam Altman. La mención de estos líderes tecnológicos destaca el papel que desempeñan en la discusión acerca de las implicaciones éticas vinculadas al desarrollo y aplicación de la *IA*. En pocas palabras, este tópico refleja el debate en torno a la responsabilidad y los desafíos éticos que acompañan a la integración de estas tecnologías en la sociedad, enfatizando la importancia de abordar estas cuestiones con una visión crítica para el avance sostenible de la *IA*.

Este análisis permite identificar los temas predominantes entre los usuarios pioneros de una de las aplicaciones más avanzadas de *IAG*, como lo es *ChatGPT*. La Figura 4.12 ofrece una perspectiva detallada sobre los tópicos más relevantes en cuanto al número de publicaciones identificadas. De manera destacada, se observa que el Tópico 4 sobresale como el más discutido en las *RRSS*, lo cual destaca el valor que la comunidad asigna a las aplicaciones prácticas actuales y futuras de los modelos de lenguaje. Este interés se justifica por el extenso abanico de aplicaciones que la *IAG* está capacitada para impulsar. Los avances potenciales que esta tecnología promete en una variedad de sectores son considerables, incrementando el interés y la atención del público hacia estos desarrollos.

En resumen, el análisis de los tópicos modelados muestra una diversidad de temáticas en cuanto al contenido compartido por los usuarios de *RRSS* sobre *ChatGPT* como *IAG*. Los tópicos abordan desde desarrollos tecnológicos hasta perspectivas futuras en *IA*, innovaciones en áreas del *NPL*, utilización práctica de modelos de lenguaje y reflexiones éticas sobre la generación de contenido. Esto muestra una gran diversidad de intereses y preocupaciones de la comunidad en torno a esta avanzada tecnología de *IA*.

Tabla 4.4: Resumen de los términos más relevantes encontrados en los 5 tópicos modelados

ID	Tópico	Palabras	Bigramas	Trigramas
1	Grandes Inversiones y Desarrollos en el Campo Tecnológico	“google”, “search”, “microsoft”, “bing”, “new”, “bard”, “openai”, “say”, “launch”, “year”	“search engine”, “sentiment result”, “artificial intelligence”, “result positive”, “google search”, “google bard”, “invest billion”, “million user”, “bing search”, “microsoft bing”,	“sentiment result positive”, “sentiment result neutral”, “sentiment result negative”, “reach million user”, “bing search engine”, “invest billion creator”, “google search engine”, “multibillion dollar investment”, “million user month”, “tender offer value”
2	Interés y Perspectivas Futuras en la IA	“new”, “article”, “future”, “thank”, “talk”, “read”, “great”, “use”, “learn”, “write”,	“artificial intelligence”, “look forward”, “late article”, “check late”, “thank share”, “tool like”, “read article”, “share thought”, “high education”, “late episode”,	“check late article”, “large language model”, “take world storm”, “future artificial intelligence”, “late article newsletter”, “artificial intelligence tool”, “use artificial intelligence”, “artificial general intelligence”, “world artificial intelligence”, “news listen podcast”
3	Innovación en el Procesamiento de Lenguaje	“new”, “use”, “tool”, “like”, “model”, “power”, “language”, “app”, “create”, “work”	“language model”, “game changer”, “large language”, “natural language”, “use case”, “tool like”, “open source”, “mind blow”, “content creation”, “exciting news”	“large language model”, “natural language processing”, “com pay interest”, “interest free instalment”, “pay interest free”, “language model like”, “coincidentally available acquisition”, “powerful language model”, “important step journey”, “cut edge technology”
4	Utilización Práctica de Modelos de Lenguaje	“ask”, “write”, “like”, “think”, “use”, “answer”, “good”, “know”, “question”, “time”	“ask write”, “ask question”, “look like”, “answer question”, “write poem”, “feel like”, “sound like”, “write code”, “write song”, “tool like”	“ask write poem”, “ask write song”, “ask right question”, “ask write rap”, “let know think”, “campaign take creative”, “take creative world”, “ask write story”, “medical licensing exam”, “coinex gainer feb”
5	Generación de Contenido y Reflexión Ética	“generate”, “create”, “like”, “use”, “text”, “video”, “bias”, “thank”, “need”, “image”	“language model”, “elon musk”, “generate text”, “thank inclusion”, “sam altman”, “social medium”, “inclusion dear”, “large language”, “political bias”, “share thank”	“thank inclusion dear”, “large language model”, “share thank inclusion”, “great share thank”, “detect generate text”, “ceo sam altman”, “language model like”, “high quality prompt”, “tool detect generate”, “human like text”

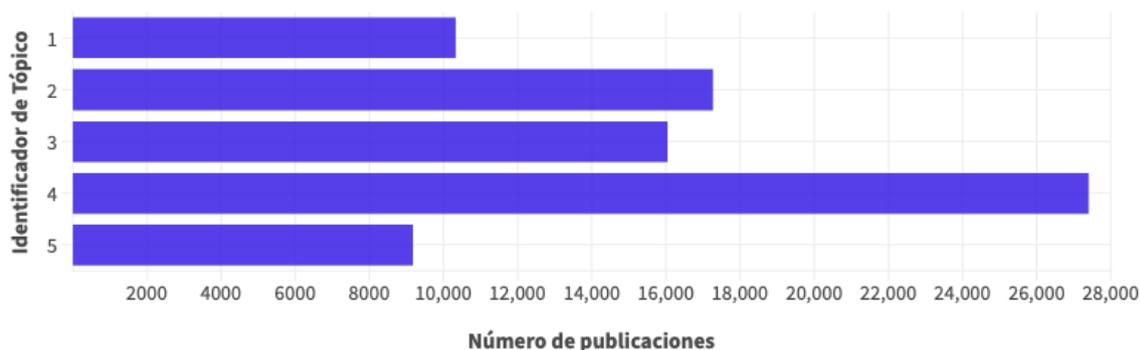


Figura 4.12: Distribución de publicaciones por Tópico. Elaboración propia

4.5. Análisis de Sentimientos

El análisis de sentimientos utiliza técnicas computacionales para distinguir la polaridad de los textos, asignando puntuaciones que identifican sentimientos negativos, positivos o neutros. Este proceso es particularmente valioso en *RRSS*, donde captura reacciones espontáneas y ofrece información relevante sobre la percepción pública. *VADER*, una técnica avanzada que mezcla análisis léxico con reglas para interpretar emociones en el lenguaje informal de las redes, se distingue por su habilidad para captar sutilezas emocionales. A diferencia del pre-procesamiento usado durante el modelado de tópicos, aquí se conservan elementos textuales esenciales como emoticonos y mayúsculas para asegurar la precisión del análisis y reflejar adecuadamente la intensidad emocional de los mensajes.

Una vez implementado el mencionado proceso de limpieza, es posible realizar el cálculo de puntuaciones sobre cada una de las publicaciones que componen el corpus. Con el fin de obtener una perspectiva comprensiva sobre la distribución de los datos, se empleó un análisis mediante un diagrama de caja, como se ilustra en la Figura 4.13. Este análisis muestra que la mediana de las puntuaciones compuestas es de 0.2869, lo que significa que el 50 % de las puntuaciones están por encima de este valor y el otro 50 % están por debajo. Los cuartiles, que representan el 25 % y el 75 % de los datos, están en 0.0 y 0.6249 respectivamente, es decir, el 25 % de las puntuaciones son menores o iguales a 0.0, otro 25 % están entre 0.0 y 0.2869, otro 25 % están entre 0.2869 y 0.6249, y el último 25 % son mayores o iguales a 0.6249. Estos primeros resultados indican que las reacciones y percepciones hacia los temas abordados en el corpus tienden hacia una polaridad positiva, reflejando una aceptación o aprecio mayoritario. Además, la media de las puntuaciones compuestas es de aproximadamente 0.2586, lo que confirma el resultado, mostrando una tendencia central positiva de las puntuaciones. Por último, la desviación estándar es de aproximadamente 0.4214, lo que sugiere una dispersión relativamente alta, pero que según lo observado se sitúa mayoritariamente en puntuaciones positivas y neutras.

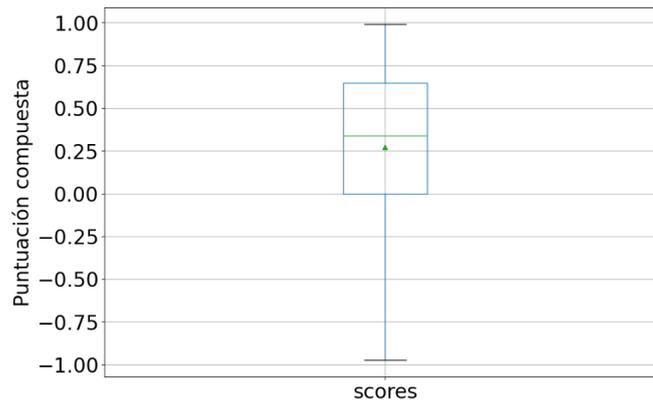


Figura 4.13: Distribución de la Puntuación de las Publicaciones. Elaboración propia

Para comprender la dinámica de los sentimientos de los usuarios de *X* hacia *ChatGPT*, se presenta la Figura 4.14. Esta gráfica muestra la evolución de la puntuación compuesta a través de acumulados diarios de las polaridades de las publicaciones durante el período estudiado. Destaca el hecho de que la puntuación compuesta acumulada nunca adopta valores negativos, indicando una tendencia generalmente positiva o neutral hacia *ChatGPT*, algo que confirma el análisis anterior. Además, es relevante mencionar que los picos significativos en esta figura coinciden con los eventos clave destacados previamente en la Figura 4.1, reforzando la conexión entre los momentos de alta actividad y la percepción pública positiva documentada al comienzo de este capítulo. El 7 de febrero, coincidiendo con los anuncios relacionados con *Bard* y *Microsoft*, se registra el nivel más alto de puntuación positiva, indicativo de una reacción de satisfacción, entusiasmo o valoración favorable de los usuarios frente a los avances tecnológicos anunciados. Después de este evento, se percibe una reducción generalizada de puntuaciones, que no asciende de nuevo hasta el 15 de marzo, fecha del lanzamiento de *GPT-4*. Este cambio en las puntuaciones sugiere que el lanzamiento de *GPT-4* generó de nuevo interés y entusiasmo entre los usuarios. Estas fluctuaciones muestran que los usuarios están atentos a los nuevos desarrollos en el campo de la *IA* y que esto fomenta interacción en las *RRSS*. Este análisis permite concluir que los lanzamientos de productos, como *GPT-4*, y demás noticias sobre el campo tienen un impacto que resulta representativo en la percepción pública de la tecnología.

Además del análisis del sentimiento general reflejado en las publicaciones a lo largo del tiempo, se ha llevado a cabo un análisis del sentimiento asociado a cada uno de los tópicos previamente identificados. Este enfoque permitió una exploración más detallada de la evolución del sentimiento respecto a temas específicos, enriqueciendo la comprensión sobre la percepción ciudadana en cada categoría de análisis. En la Figura 4.15, se muestran los resultados del análisis de sentimientos cuando las publicaciones son segmentadas por tópico, mientras que en la Tabla 4.5 se detallan las estadísticas clave de la Puntuación Compuesta para cada área temática, proporcionando información relevante sobre las variaciones en la

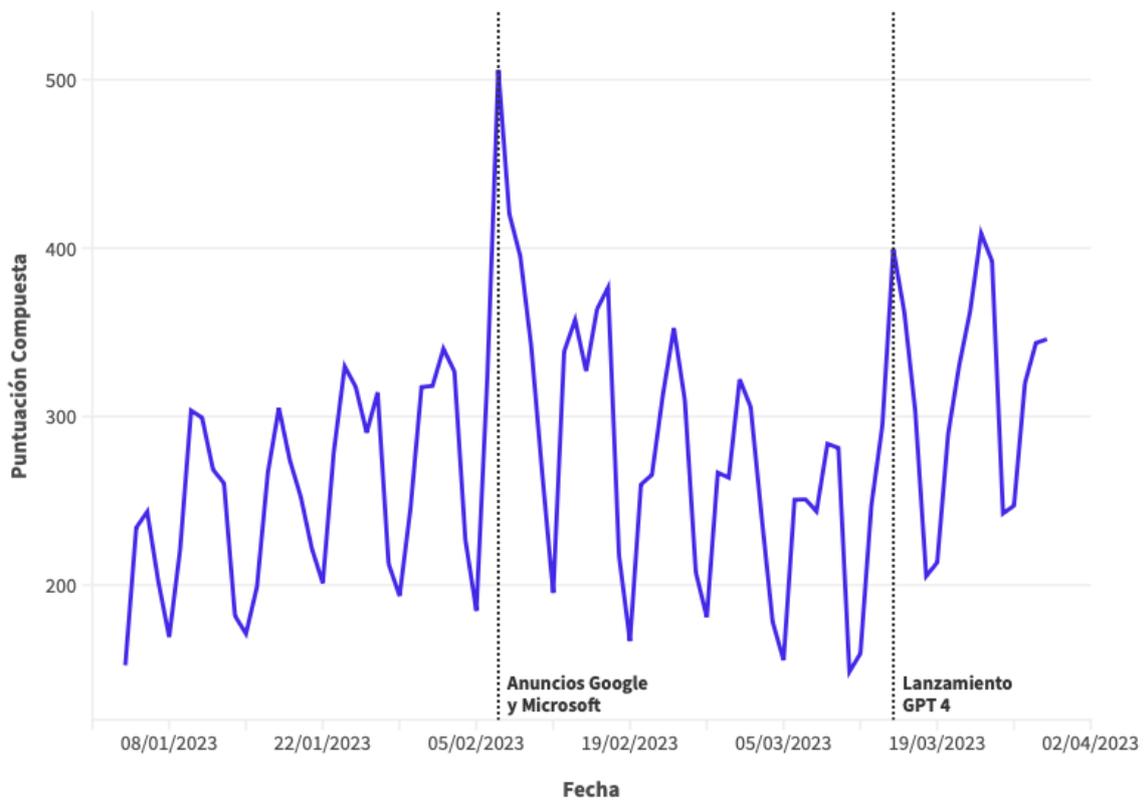


Figura 4.14: Puntuación Compuesta del Corpus. Elaboración propia

percepción del público en función de los distintos temas abordados.

En primer lugar, el Tópico 1, “Grandes Inversiones y Desarrollos en el Campo Tecnológico”, revela predominantemente sentimientos neutros, con una tendencia ligeramente positiva, evidenciada por una puntuación promedio de 17.99. Este tópico destaca por presentar tanto la puntuación mínima más baja como la media más baja entre los analizados, sugiriendo una percepción general menos positiva de esta temática. La neutralidad de los sentimientos puede estar asociada con la cobertura objetiva de noticias y avances tecnológicos, los cuales, a pesar de ser prometedores, pueden generar inquietudes sobre su integración en la sociedad o los retos emergentes. Las puntuaciones moderadamente positivas, por su parte, podrían indicar un reconocimiento del avance y progreso en el sector tecnológico. En resumen, se puede deducir que los usuarios mantienen una percepción neutral con ciertas precauciones respecto a estas noticias. Esto se manifiesta especialmente el 7 de febrero, día en que se registró la puntuación máxima, reflejando la acogida positiva hacia los anuncios sobre *Bard*. No obstante, el 15 de marzo, coincidiendo con el lanzamiento de *GPT-4*, se percibe un cierto rechazo o preocupación hacia la herramienta.

Posteriormente, el Tópico 2 denominado “Interés y Proyecciones Futuras en IA”, muestra principalmente sentimientos positivos, aunque se caracterizan por tener fuertes fluctuaciones en el transcurso del tiempo. Registrando una puntuación media elevada de 71.87, esta tenden-

cia positiva posiblemente refleje el optimismo y expectativas hacia el impacto transformador de la IA en diversas facetas de la sociedad. La anticipación de desarrollos futuros y las perspectivas alentadoras pueden estar impulsando esta percepción optimista.

El Tópico 3 denominado “Innovación en el Procesamiento de Lenguaje”, refleja sentimientos que oscilan entre neutros y moderadamente positivos, comportamiento evidenciado por una puntuación media de 65.56. La neutralidad en los sentimientos puede deberse a la exposición objetiva de los progresos en el procesamiento del lenguaje, mientras que el matiz positivo sugiere un creciente interés y expectativa hacia las capacidades revolucionarias de los grandes modelos de lenguaje en variados sectores. Un pico de entusiasmo se observa específicamente el 7 de febrero, coincidiendo con el lanzamiento de *Bard*. Este evento resalta el reconocimiento por parte de la comunidad de su significativo potencial, reafirmando la creciente consideración de *Bard* como un competidor directo de *ChatGPT*.

El Tópico 4, etiquetado como “Aplicaciones Prácticas de Modelos de Lenguaje”, se distingue como el más positivamente valorado, reflejado en una puntuación media de 100. Tal positividad se puede atribuir al evidente entusiasmo y a la valoración de la utilidad que los modelos de lenguaje avanzados poseen para la creación de contenido y la solución de retos prácticos en ámbitos tan variados como la educación y el marketing. La apreciación hacia estos modelos no solo resalta su capacidad para facilitar tareas específicas, sino también su potencial para impulsar la innovación en estas áreas críticas, transformando métodos tradicionales y abriendo nuevas vías para la comunicación y el aprendizaje.

El Tópico 5, “Creación de Contenido y Consideraciones Éticas”, es la temática con la menor puntuación. A lo largo de la línea temporal, se puede observar que el tópico nunca alcanza puntuaciones superiores a 50, a diferencia de todos los otros tópicos. Estos sentimientos neutros podrían estar relacionados con el debate sobre la calidad del contenido generado por herramientas de IA y las consideraciones éticas asociadas. Esta neutralidad podría deberse a una deliberación equilibrada entre el reconocimiento del potencial innovador y transformador de estos modelos para enriquecer la creación de contenido y, por otro lado, la conciencia crítica sobre las preocupaciones éticas que emergen, tales como la autenticidad del contenido, la originalidad, y las implicaciones de su uso en la propagación de información errónea o el plagio.

En la Figura 4.16, se muestra un diagrama de caja para cada tópico, ilustrando las principales métricas de dispersión y tendencia central de los sentimientos asociados. El primer tópico presenta una notable dispersión y una tendencia hacia puntuaciones inferiores al valor mediano. Los tópicos 2 y 3, por su parte, registran puntajes medios de sentimiento más elevados y desviaciones típicas amplias, indicando una variabilidad significativa en las reacciones emocionales. El segundo tópico muestra una asimetría negativa, señalando una inclinación hacia opiniones más positivas; mientras que el tercer tópico, con asimetría positiva, muestra una ligera concentración de puntuaciones hacia el extremo menos positivo. En contraste, el cuarto tópico revela una asimetría próxima a cero, indicando una distribución balanceada de

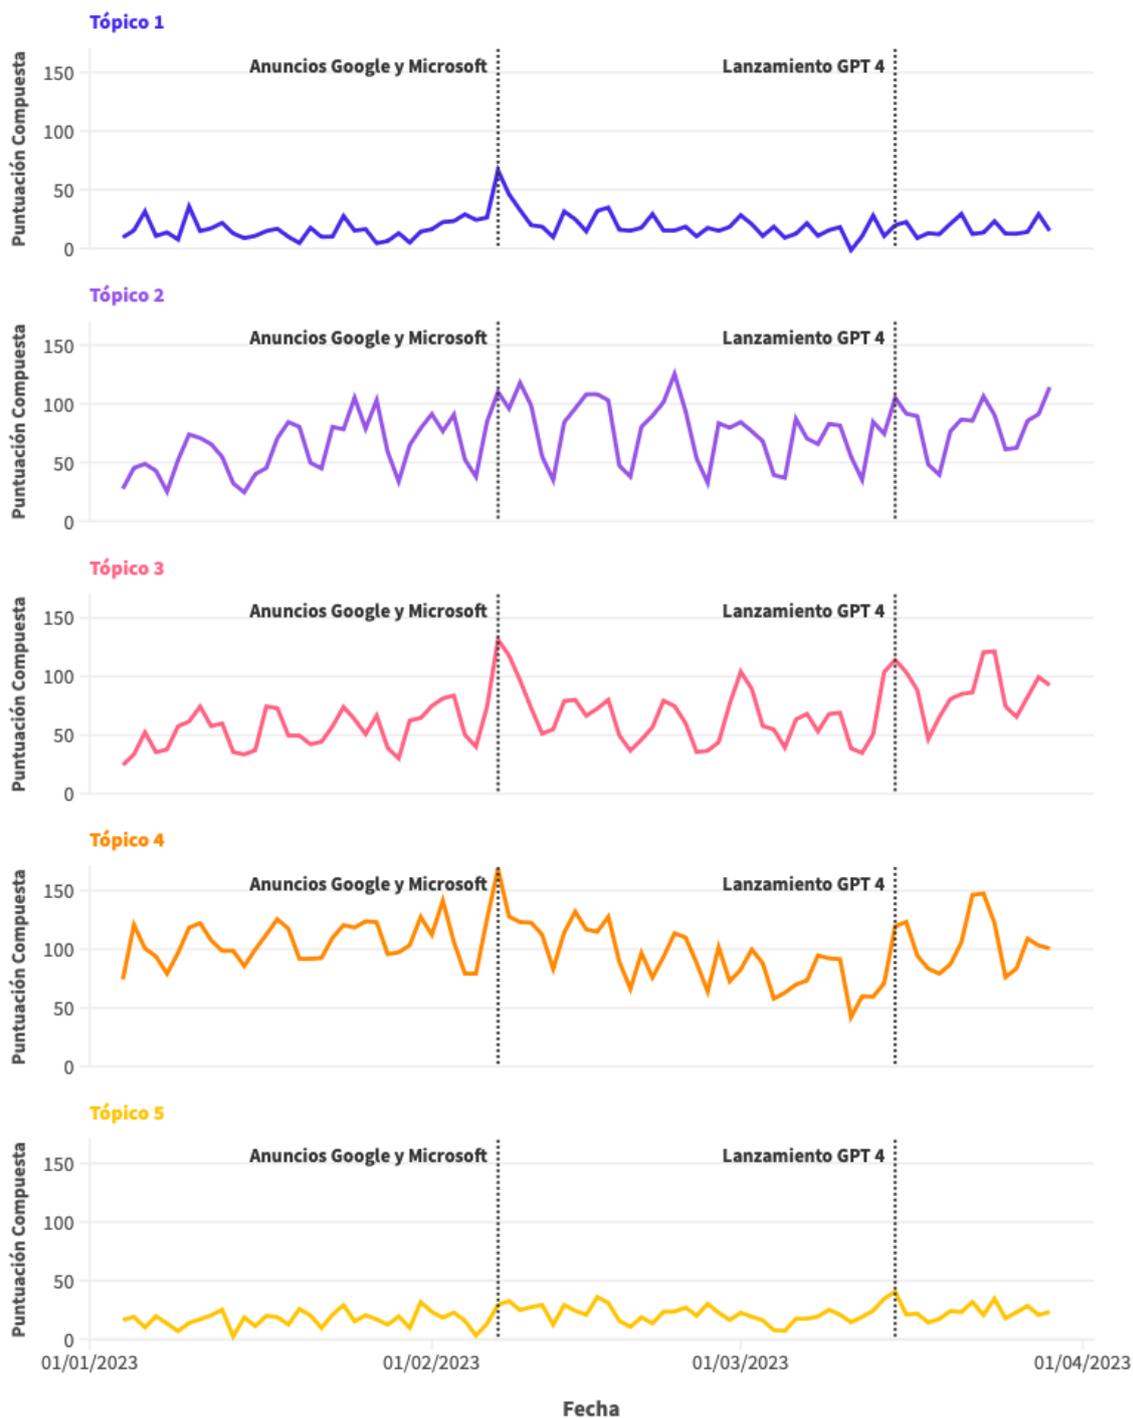


Figura 4.15: Puntuación Compuesta por Tópico. Elaboración propia

las opiniones alrededor de la mediana, el cual tiene el valor de sentimiento más alto entre todos. Finalmente, el quinto tópico destaca por tener la menor desviación típica, sugiriendo uniformidad en las reacciones emocionales, posiblemente hacia una neutralidad más marcada.

Tabla 4.5: Resumen Estadístico del Sentimiento por Tópicos

Tópico	Punt. Máxima	Punt. Mínima	Media	Desv. Típica	Coef. Asimetría
1	66.52	-1.52	17.99	9.86	1.79
2	125.41	24.52	71.87	24.96	-0.12
3	131.26	24.59	65.56	23.64	0.63
4	168.36	42.01	100.41	23.01	0.08
5	40.58	2.43	20.23	7.43	0.13

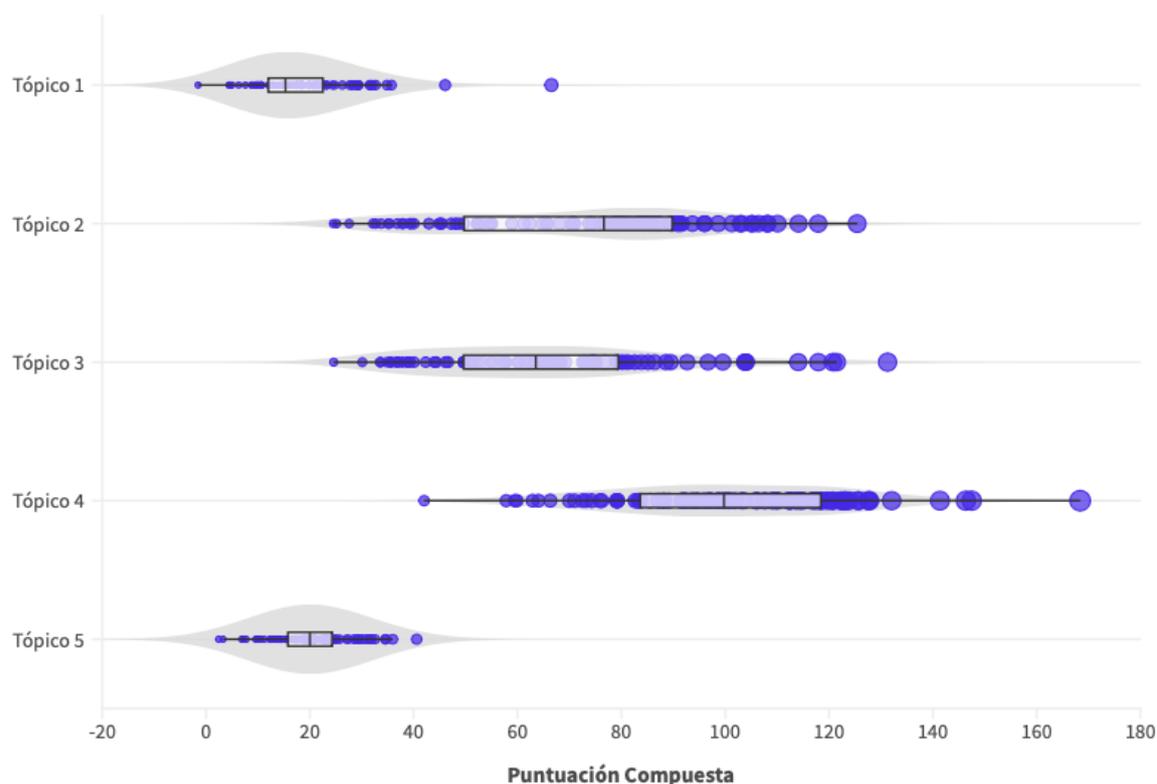


Figura 4.16: Dispersión de Sentimiento por Tópico. Elaboración propia

Resumidamente, los resultados de este análisis ofrecen una visión detallada de las percepciones ciudadanas hacia una serie de temas relevantes asociados con el desarrollo de *ChatGPT*. El Tópico 1, sobre inversiones tecnológicas, muestra una percepción neutral. Por otro lado, el Tópico 2, relacionado con la *IA*, refleja optimismo y expectativas futuras. El Tópico 3, sobre innovación en procesamiento de lenguaje, exhibe una mezcla de neutralidad y optimismo, destacando el lanzamiento de *Bard* como un momento de entusiasmo. El Tópico 4, centrado en aplicaciones prácticas de modelos de lenguaje, es el más positivo, reflejando un alto entusiasmo por su utilidad y potencial innovador. Finalmente, el Tópico 5, sobre creación de contenido y consideraciones éticas, muestra una neutralidad persistente, posiblemente debido al debate sobre la calidad del contenido generado y las preocupaciones éticas.

Asimismo, con el fin de complementar el análisis, se evaluó el impacto de los fines de semana en el análisis de sentimientos, extendiendo la observación inicial presentada en la Figura 4.17. Previamente, se había detectado una significativa disminución en la frecuencia de publicaciones durante los sábados y domingos, según se evidencia en la Figura 4.2. Este patrón llevó a investigar si tal tendencia afectaba igualmente la polaridad de las publicaciones. El análisis reveló que, durante los fines de semana, no solo se reduce el volumen de publicaciones mencionando a *ChatGPT*, sino también la puntuación acumulada de los sentimientos expresados en estos posts, en contraste con los días laborables.

Esta diferencia puede ser atribuida a varios factores interrelacionados. Primero, los patrones de uso de las *RRSS* cambian durante los fines de semana, ya que la gente tiende a disminuir su actividad en línea debido a compromisos personales o periodos de descanso. Esta menor actividad general podría resultar en una disminución en el volumen de publicaciones sobre temas diversos. Además, la finalidad de uso de las *RRSS* varía entre los días laborales y los fines de semana; en días hábiles, suelen emplearse para fines profesionales, educativos o laborales, incluyendo debates sobre tecnología e *IA* relevantes a *ChatGPT*. Por el contrario, los fines de semana se destinan más a actividades recreativas, disminuyendo el interés por discusiones técnicas. Así, las preferencias y prioridades de los usuarios respecto al contenido que comparten en *RRSS* se ven influenciadas por el día de la semana.

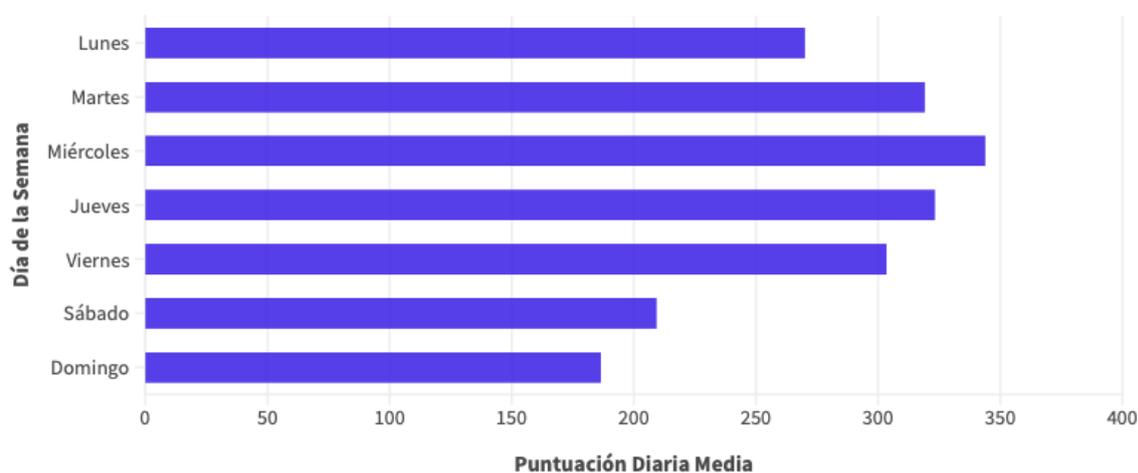


Figura 4.17: Puntuación Compuesta por Día de la Semana. Elaboración propia

En conclusión, el análisis presentado en esta sección destaca que los tópicos identificados presentan variaciones en las puntuaciones de sentimiento, predominando las tendencias positivas o neutras. Además, los resultados muestran un interés sustancial por parte de los usuarios hacia los avances en tecnología e *IA*, si bien emergen ciertas reservas e inquietudes. Para *ChatGPT*, implica la necesidad de mantenerse al tanto de estos matices en la percepción pública y adaptar su comunicación y funciones en consecuencia. Además, proporciona información valiosa sobre las expectativas y preocupaciones de los primeros usuarios de este tipo

de IA, lo que puede ayudar a orientar el desarrollo y la mejora continua de *ChatGPT* para satisfacer las necesidades y expectativas cambiantes de los usuarios.

Capítulo 5

Conclusiones

El objetivo principal de este *TFG en Business Analytics* ha sido explorar la percepción pública de *ChatGPT*, tratándolo como una herramienta de *IAG* de carácter innovador y disruptivo en el panorama tecnológico reciente. Para alcanzar este fin, se ha procedido a la compilación y análisis de datos extraídos de publicaciones en la plataforma *X*, buscando identificar las principales categorías temáticas de discusión y evaluar el sentimiento general manifestado. Las plataformas de *RRSS*, y en particular *X*, se han destacado como escenarios adecuados para este tipo de análisis, dada su capacidad para reflejar de manera fidedigna la percepción colectiva. Este fenómeno se debe a su rapidez, alcance global y la oportunidad que ofrecen a los usuarios para expresarse de manera espontánea y sin restricciones.

Con el propósito establecido, la fase inicial de este *TFG* consistió en una exploración de la literatura existente, con el fin de establecer una base sobre las metodologías empleadas actualmente para el análisis automático de percepciones públicas en *RRSS* hacia tecnologías innovadoras, incluyendo *ChatGPT*. Esta revisión comprendió estudios relacionados con avances tecnológicos, abarcando desde servicios en la nube hasta el Metaverso, todos orientados a entender las opiniones expresadas en las *RRSS*. Las investigaciones revisadas describen las distintas metodologías usadas para el análisis automático de textos, destacando especialmente el uso de *LDA* para el modelado de tópicos y de *VADER* para el análisis de sentimientos. La elección de *LDA* se justifica por su eficiencia en el procesamiento y categorización de grandes volúmenes de texto. Esta técnica facilita la identificación y agrupación natural de los contenidos sin la necesidad de etiquetas previas, requiriendo únicamente el corpus y el número de tópicos a identificar. Por otro lado, *VADER* destaca por su capacidad para analizar con precisión textos breves y el lenguaje informal predominante en las *RRSS*. Esta técnica captura los detalles de las variaciones en las emociones y tonalidades más complejas expresadas, siendo así adecuado para el presente estudio.

Tras establecer las estrategias analíticas a implementar, se desarrolla un proceso metodológico estructurado en cinco secciones clave. Inicialmente, se aborda la adquisición y preparación de los datos, optando por fuentes de repositorios públicos debido a las limitaciones

para acceder a la *API* de *X*. La fase de pre-procesamiento está orientada a aplicar tratamientos como la tokenización, la eliminación de caracteres especiales y *stop-words*, y la lematización, necesarios para garantizar la calidad del corpus. A continuación, se procede a la exploración de *n-gramas* y la implementación de la métrica *TF-IDF* para cuantificar la relevancia de los términos dentro del corpus. Posteriormente, la etapa de modelado de tópicos emplea *LDA* para identificar y catalogar los temas centrales de la discusión. Finalmente, se aplica el análisis de sentimientos, centrado en *VADER*, para evaluar la polaridad emocional de los textos.

Una vez aplicada esta metodología, el análisis descriptivo mostró la relación existente entre los acontecimientos significativos en el ámbito tecnológico y el comportamiento de los usuarios en plataformas sociales, evidenciando picos de actividad coincidentes con eventos claves como los lanzamientos de *GPT-4* y *Bard*. Estos momentos destacan la capacidad de tales desarrollos para captar la atención y generar discusión dentro de la comunidad en línea. Asimismo, la amplia variedad de idiomas presentes en el corpus, con un total de 49, destaca el interés y la repercusión global de *ChatGPT*, con el inglés presentándose como el idioma más utilizado. Los *hashtags* observados durante el estudio muestran un fuerte enfoque en entidades y aplicaciones vinculadas al ámbito de la *IA*, tales como *Google*, *Microsoft* y *OpenAI*, además de conceptos relacionados con la *IAG*, incluyendo *ML*, y *chatbots*.

Por su parte, el modelado de tópicos identificó cinco temas principales presentes en el corpus de texto: grandes inversiones y desarrollos en tecnología, interés y proyecciones futuras en *IA*, innovación en el procesamiento de lenguaje, aplicaciones prácticas de modelos de lenguaje y consideraciones éticas sobre la generación de contenido. El análisis de sentimientos mostró una inclinación hacia reacciones positivas, marcando momentos de gran interés en torno a eventos significativos previamente mencionados. Los tópicos relacionados con la innovación tecnológica muestran optimismo, mientras que el debate sobre ética y las grandes inversiones refleja polaridades más bajas, posiblemente debido a preocupaciones éticas y de calidad. La prevalencia de una actitud positiva hacia *ChatGPT* en los resultados valida su recepción favorable en el entorno digital, reflejando una confianza sustancial en las capacidades de la *BD* lo que aporta una base para potenciar la innovación en el campo tecnológico. Es importante también destacar la conversación en torno a los usos prácticos de *ChatGPT*, mostrando su potencial benéfico para la colectividad, lo cual promueve la integración de tecnologías afines en sectores críticos como la educación, el cuidado de la salud y el comercio digital.

La detección de tonalidades más neutras en ámbitos vinculados a inversiones y consideraciones éticas indica la necesidad de que las compañías aborden estos temas con sensibilidad y transparencia. En el ámbito de las inversiones, este resultado sugiere que el diálogo podría centrarse en el análisis de noticias y desarrollos tecnológicos, donde se espera una comunicación clara y objetiva sobre estos avances. Por otro lado, la presencia de polaridades más bajas en relación a las consideraciones éticas resalta la importancia de abordar estas preocupaciones de manera abierta. La reflexión sobre las implicaciones éticas de la tecnología, incluyendo

potenciales sesgos y efectos sobre la privacidad, se convierte en un tema necesario de debate para generar confianza y facilitar una adopción consciente y responsable.

En investigaciones futuras dentro de este ámbito, se sugiere ampliar el marco temporal del análisis. Tal ampliación facilitaría la identificación de posibles variaciones en las percepciones y en las interacciones de la comunidad en línea con respecto a *ChatGPT*. Además, proporcionaría la oportunidad de discernir tendencias de largo plazo en la opinión pública. Asimismo, incorporar análisis en diversos idiomas proporcionaría una visión más completa sobre las actitudes hacia *ChatGPT* a nivel mundial, permitiendo evaluar las diferencias culturales en la percepción y adopción de esta tecnología. En los resultados de este estudio se observó un incremento en el volumen de interacciones y polaridades positivas durante los fines de semana, lo que sugiere la necesidad de investigar más detalladamente las causas de este fenómeno en futuros trabajos. Además, sería relevante explorar otros factores que influyen en las interacciones en *RRSS* y los resultados de estudios similares. Entre estos, se podrían considerar la incidencia de eventos puntuales, patrones estacionales, o la influencia de la ubicación geográfica de los usuarios, tal como se ha indicado previamente.

Como conclusión final, este estudio destaca la gran aceptación que *ChatGPT* ha obtenido entre sus primeros usuarios, lo cual es un resultado que impulsa tanto el avance como la inversión en el ámbito de las tecnologías generativas. Además, esta aceptación no solo refleja el reconocimiento de su utilidad práctica y capacidad de innovación en diversos sectores, sino que también abre caminos para futuras investigaciones en el campo de la *IA*.

Declaración de Uso de Herramientas de Inteligencia Artificial Generativa en Trabajos Fin de Grado

ADVERTENCIA: Desde la Universidad consideramos que *ChatGPT* u otras herramientas similares son herramientas muy útiles en la vida académica, aunque su uso queda siempre bajo la responsabilidad del alumno, puesto que las respuestas que proporciona pueden no ser veraces. En este sentido, NO está permitido su uso en la elaboración del Trabajo fin de Grado para generar código porque estas herramientas no son fiables en esa tarea. Aunque el código funcione, no hay garantías de que metodológicamente sea correcto, y es altamente probable que no lo sea.

Por la presente, yo, Elena Suárez García, estudiante de Doble Grado en ADE y Business Analytics (E-2 + Analytics) de la Universidad Pontificia Comillas al presentar mi Trabajo Fin de Grado titulado “Descifrando la Percepción Pública sobre *ChatGPT*: Un Estudio a partir del Análisis Automático de Publicaciones de X”, declaro que he utilizado la herramienta de Inteligencia Artificial Generativa *ChatGPT* u otras similares de IAG de código sólo en el contexto de las actividades descritas a continuación:

1. Brainstorming de ideas de investigación: Utilizado para idear y esbozar posibles áreas de investigación.
2. Interpretador de código: Para realizar análisis de datos preliminares.
3. Constructor de plantillas: Para diseñar formatos específicos para secciones del trabajo.
4. Corrector de estilo literario y de lenguaje: Para mejorar la calidad lingüística y estilística del texto.
5. Generador previo de diagramas de flujo y contenido: Para esbozar diagramas iniciales.
6. Sintetizador y divulgador de libros complicados: Para resumir y comprender literatura compleja.
7. Revisor: Para recibir sugerencias sobre cómo mejorar y perfeccionar el trabajo con diferentes niveles de exigencia.
8. Traductor: Para traducir textos de un lenguaje a otro.

Afirmo que toda la información y contenido presentados en este trabajo son producto de mi investigación y esfuerzo individual, excepto donde se ha indicado lo contrario y se han dado los créditos correspondientes (he incluido las referencias adecuadas en el TFG y he explicitado para que se ha usado *ChatGPT* u otras herramientas similares). Soy consciente de las implicaciones académicas y éticas de presentar un trabajo no original y acepto las consecuencias de cualquier violación a esta declaración.

Fecha: Abril 2024

Firma: Elena Suárez García

Referencias

- Ahmad, M., Aftab, S., y Ali, I. (2017). Sentiment analysis of tweets using svm. *Int. J. Comput. Appl.*, 177(5), 25–29.
- Akkuzukaya, G. (2022). Sentiment analysis on the metaverse: Twitter data. *Sakarya University Journal of Computer and Information Sciences*, 5(2), 147–156.
- Al-Kfairy, M., Al-Adaileh, A., Tubishat, M., Alfandi, O., BinAmro, M., y Alomari, A. (2023). A sentiment analysis approach for identifying users' security and privacy perception of metaverse in twitter. En *2023 international conference on smart applications, communications and networking (smartnets)* (pp. 1–6).
- Al-Obaydy, W. N. I., Hashim, H. A., Najm, Y., y Jalal, A. A. (2022). Document classification using term frequency-inverse document frequency and k-means clustering. *Indonesian Journal of Electrical Engineering and Computer Science*, 27(3), 1517–1524.
- Baviera, T. (2017). Técnicas para el análisis del sentimiento en twitter: Aprendizaje automático supervisado y sentistrength. *Dígitos*, 1(3), 33–50.
- BBC. (2023). 'gpt-4: qué novedades presenta la nueva versión del chat de inteligencia artificial'. (acceso Marzo 6, 2024) <https://www.bbc.com/mundo/noticias-64969661/>.
- Blei, D. M., Ng, A. Y., y Jordan, M. I. (2003). Latent dirichlet allocation. *Journal of machine Learning research*, 3(Jan), 993–1022.
- Bonta, V., Kumares, N., y Janardhan, N. (2019). A comprehensive study on lexicon based approaches for sentiment analysis. *Asian Journal of Computer Science and Technology*, 8(S2), 1–6.
- Brooker, P., Barnett, J., y Cribbin, T. (2016). Doing social media analytics. *Big Data & Society*, 3(2), 2053951716658060.
- Caleffi, P.-M. (2015). The 'hashtag': A new word or a new rule? *SKASE journal of theoretical linguistics*, 12(2).
- Correa, J. C. (2023). Chat gpt. lecciones para el desarrollo y la innovación empresarial.
- De Angelis, L., Baglivo, F., Arzilli, G., Privitera, G. P., Ferragina, P., Tozzi, A. E., y Rizzo, C. (2023). Chatgpt and the rise of large language models: the new ai-driven infodemic threat in public health. *Frontiers in Public Health*, 11, 1166120.
- Del Prete, A., y Redon Pantoja, S. (2020). Las redes sociales on-line: Espacios de socializa-

- ción y definición de identidad. *Psicoperspectivas*, 19(1), 86–96.
- Elbagir, S., y Yang, J. (2019). Twitter sentiment analysis using natural language toolkit and vader sentiment. En *Proceedings of the international multiconference of engineers and computer scientists* (Vol. 122, p. 16).
- Europa Press. (2023). ‘microsoft presenta la nueva versión de bing y edge, que incorporan la ia de chatgpt para reinventar’la búsqueda’. (acceso Marzo 6, 2024) <https://www.europapress.es/portaltic/internet/noticia-microsoft-presenta-nueva-version-bing-edge-incorporan-ia-chatgpt-reinventar-busqueda-20230208110307/>.
- Farina, M., y Lavazza, A. (2023). Chatgpt in society: emerging issues. *Frontiers in Artificial Intelligence*, 6, 1130913.
- Forbes. (2023). ‘google lanza de forma limitada bard, rival de chatgpt’. (acceso Marzo 6, 2024) <https://forbes.es/empresas/229656/google-lanza-de-forma-limitada-bard-rival-de-chatgpt/>.
- Google. (2023). ‘google trends’. (acceso Septiembre 26, 2023) <https://trends.google.com/home>.
- Gutiérrez-Caneda, B., Vázquez-Herrero, J., y López-García, X. (2023). Ai application in journalism: Chatgpt and the uses and risks of an emergent technology. *Profesional de la información*, 32(5).
- Hammoe, L. (2018). Detección de tópicos: utilizando el modelo lda.
- Haque, M. U., Dharmadasa, I., Sworna, Z. T., Rajapakse, R. N., y Ahmad, H. (2022). ‘i think this is the most disruptive technology’: Exploring sentiments of chatgpt early adopters using twitter data. *arXiv preprint arXiv:2212.05856*.
- Havrlant, L., y Kreinovich, V. (2017). A simple probabilistic explanation of term frequency-inverse document frequency (tf-idf) heuristic (and variations motivated by this explanation). *International Journal of General Systems*, 46(1), 27–36.
- Hornik, K., Rauch, J., y Christian Buchta, I. F. (2023). ‘n-gram based text categorization’. (acceso Marzo 8, 2024) <https://cran.r-project.org/web/packages/textcat/textcat.pdf>.
- Hutto, C., y Gilbert, E. (2014). Vader: A parsimonious rule-based model for sentiment analysis of social media text. , 8(1), 216–225.
- Ibáñez-Sosa, G. (2023). Aplicación de modelado de tópicos en reseñas de hospedajes de airbnb en berlin de 2010 a 2019.
- Karamouzas, D., Mademlis, I., y Pitas, I. (2022). Public opinion monitoring through collective semantic analysis of tweets. *Social Network Analysis and Mining*, 12(1), 91.
- Kasneci, E., Seßler, K., Küchemann, S., Bannert, M., Dementieva, D., Fischer, F., ... others (2023). Chatgpt for good? on opportunities and challenges of large language models for education. *Learning and individual differences*, 103, 102274.
- Khalid Ansari. (2023). ‘500k chatgpt-related tweets jan-mar 2023’. (acceso Sep-

- tiembre 12, 2023) <https://www.kaggle.com/datasets/khalidryder777/500k-chatgpt-tweets-jan-mar-2023/data>.
- Korkmaz, A., Aktürk, C., y TALAN, T. (2023). Analyzing the user's sentiments of chatgpt using twitter data. *Iraqi Journal For Computer Science and Mathematics*, 4(2), 202–214.
- Lampropoulos, G., Keramopoulos, E., Diamantaras, K., y Evangelidis, G. (2022). Augmented reality and virtual reality in education: Public perspectives, sentiments, attitudes, and discourses. *Education Sciences*, 12(11), 798.
- Lin, J. (2016). On the dirichlet distribution. *Department of Mathematics and Statistics, Queens University*, 10–11.
- Martos Carrión, E. (2011). *Análisis sobre las nuevas formas de comunicación a través de las comunidades virtuales o redes sociales* (Tesis Doctoral no publicada). Universitat Politècnica de València.
- Morales-Chan, M. A. (2023). Explorando el potencial de chat gpt: Una clasificación de prompts efectivos para la enseñanza.
- Müller, M., Schneider, M., Salathé, M., y Vayena, E. (2020). Assessing public opinion on crispr-cas9: combining crowdsourcing and deep learning. *Journal of medical Internet research*, 22(8), e17830.
- Nerdynav. (2024). '107 up-to-date chatgpt statistics user numbers'. (acceso Febrero 13, 2024) <https://nerdynav.com/chatgpt-statistics/>.
- Onan, A., Korukoglu, S., y Bulut, H. (2016). Lda-based topic modelling in text sentiment classification: An empirical analysis. *Int. J. Comput. Linguistics Appl.*, 7(1), 101–119.
- Orquín, A. F. (2009). *Sistema para el pre-procesamiento de textos para el procesamiento del lenguaje natural. text pre-processing system for natural language processing* (Tesis Doctoral no publicada). Universidad de Matanzas.
- Park, C. W., y Seo, D. R. (2018). Sentiment analysis of twitter corpus related to artificial intelligence assistants. En *2018 5th international conference on industrial engineering and applications (iciea)* (pp. 495–498).
- Qaisi, L. M., y Aljarah, I. (2016). A twitter sentiment analysis for cloud providers: A case study of azure vs. aws. En *2016 7th international conference on computer science and information technology (csit)* (pp. 1–6).
- Qi, W., Pan, J., Lyu, H., y Luo, J. (2023). Excitements and concerns in the post-chatgpt era: Deciphering public perception of ai through social media analysis. *arXiv preprint arXiv:2307.05809*.
- Ré, M. A., Prato, D. P., y Lamberti, P. W. (2008). Discriminación de distribuciones de probabilidad usando distancias entrópicas. , 19(1).
- Saputra, R., Nasution, M. I. P., y Dharma, B. (2023). The impact of using ai chat gpt on marketing effectiveness: A case study on instagram marketing. *Indonesian Journal of Economics and Management*, 3(3), 603–617.

- Sarlan, A., Nadam, C., y Basri, S. (2014). Twitter sentiment analysis. En *Proceedings of the 6th international conference on information technology and multimedia* (pp. 212–216).
- Sobrino Sande, J. C. (2018). Análisis de sentimientos en twitter.
- Sohail, S. S., Farhat, F., Himeur, Y., Nadeem, M., Madsen, D. Ø., Singh, Y., ... Mansoor, W. (2023). Decoding chatgpt: A taxonomy of existing research, current challenges, and possible future directions. *Journal of King Saud University-Computer and Information Sciences*, 101675.
- Statista. (2023). 'threads shoots past one million user mark at lightning speed?'. (acceso Septiembre 26, 2023) <https://www.statista.com/chart/29174/time-to-one-million-users/>.
- Suárez García, E. (2024). 'chatgpt perception analysis'. (acceso Marzo 27, 2024) <https://github.com/elenasuarez/ChatGPT-Perception-Analysis.git>.
- Toni Vitali. (2023). 'chatgpt statistics'. (acceso Septiembre 26, 2023) <https://investingintheweb.com/education/chatgpt-statistics/>.