



UNIVERSIDAD NACIONAL DE CHIMBORAZO
FACULTAD DE INGENIERÍA
CARRERA DE INGENIERÍA EN TECNOLOGÍAS DE LA
INFORMACIÓN

**Desarrollo de una aplicación web para el análisis de sentimientos
en publicaciones y comentarios de Instagram utilizando técnicas de
IA**

**Trabajo de Titulación para optar al título de Ingeniero en
Tecnologías de la Información**

Autor:

Vera Palacios Daniel Andrés

Tutor:

Ing. Ximena Alexandra Quintana López Ph.D.


Riobamba, Ecuador. 2025

DECLARATORIA DE AUTORÍA

Yo, Daniel Andrés Vera Palacios, con cédula de ciudadanía 080413836-0, autor del trabajo de investigación titulado: Desarrollo de una aplicación web para el análisis de sentimientos en publicaciones y comentarios de Instagram utilizando técnicas de IA, certifico que la producción, ideas, opiniones, criterios, contenidos y conclusiones expuestas son de mi exclusiva responsabilidad.

Asimismo, cedo a la Universidad Nacional de Chimborazo, en forma no exclusiva, los derechos para su uso, comunicación pública, distribución, divulgación y/o reproducción total o parcial, por medio físico o digital; en esta cesión se entiende que el cesionario no podrá obtener beneficios económicos. La posible reclamación de terceros respecto de los derechos de autor (a) de la obra referida, será de mi entera responsabilidad; librando a la Universidad Nacional de Chimborazo de posibles obligaciones.

En Riobamba, 17 de diciembre de 2025.



.....

Daniel Andrés Vera Palacios

C.I: 0804138360



DICTAMEN FAVORABLE DEL PROFESOR TUTOR

Quien suscribe, Ing. Ximena Alexandra Quintana López catedrático adscrito a la Facultad de Ingeniería, por medio del presente documento certifico haber asesorado y revisado el desarrollo del trabajo de investigación titulado: Desarrollo de una aplicación web para el análisis de sentimientos en publicaciones y comentarios de Instagram utilizando técnicas de IA, bajo la autoría del estudiante Vera Palacios Daniel Andrés con CC: 0804138360, de la carrera de Ingeniería en Tecnologías de la Información y dando cumplimiento a los criterios metodológicos exigidos; por lo que se autoriza ejecutar los trámites legales para su sustentación.

Es todo cuanto informar en honor a la verdad; en Riobamba, a los 4 días del mes de noviembre de 2025.



Firmado electrónicamente por:
**XIMENA ALEXANDRA
QUINTANA LOPEZ**

Validar únicamente con FirmaEC

PhD. Ximena Alexandra Quintana López
TUTORA

CERTIFICADO DE LOS MIEMBROS DEL TRIBUNAL

Quienes suscribimos, catedráticos designados Miembros del Tribunal de Grado para la evaluación del trabajo de investigación “Desarrollo de una aplicación web para el análisis de sentimientos en publicaciones y comentarios de Instagram utilizando técnicas de IA”, presentado por Daniel Andrés Vera Palacios, con cédula de identidad número 0804138360, bajo la tutoría de Ph.D. Ximena Alexandra Quintana López; certificamos que recomendamos la APROBACIÓN de este con fines de titulación. Previamente se ha evaluado el trabajo de investigación y escuchada la sustentación por parte de su autor; no teniendo más nada que observar.

De conformidad a la normativa aplicable firmamos, en Riobamba el 17 de diciembre de 2025.

Ing. Lady Espinoza. Mgs.

PRESIDENTE DEL TRIBUNAL DE GRADO



Ing. Lidia Castro. Mgs.

MIEMBRO DEL TRIBUNAL DE GRADO



Ing. Gonzalo Allauca. Mgs.

MIEMBRO DEL TRIBUNAL DE GRADO





CERTIFICACIÓN

Que, **Vera Palacios Daniel Andrés** con CC: **0804138360**, estudiante de la Carrera **Ingeniería en Tecnologías de la Información**, Facultad de **Ingeniería**; ha trabajado bajo mi tutoría el trabajo de investigación titulado "**DESARROLLO DE UNA APLICACIÓN WEB PARA EL ANÁLISIS DE SENTIMIENTOS EN PUBLICACIONES Y COMENTARIOS DE INSTAGRAM UTILIZANDO TÉCNICAS DE IA**", cumple con el 1 %, de acuerdo al reporte del sistema Anti plagio **Compilatio**, porcentaje aceptado de acuerdo a la reglamentación institucional, por consiguiente autorizo continuar con el proceso.

Riobamba, 02 de diciembre de 2025



Firmado electrónicamente por:
**XIMENA ALEXANDRA
QUINTANA LOPEZ**

Validar únicamente con FirmaBC

PhD. Ximena Quintana
TUTORA

DEDICATORIA

Hoy quiero dedicar este trabajo a todas las personas que han sido pilares en mi vida y que, de una u otra forma, han contribuido a que este logro sea posible.

A mi madre, Magalis, que me dio la vida y me enseñó con amor, paciencia y esfuerzo el valor del trabajo, la honestidad y la perseverancia. Tu apoyo incondicional ha sido mi mayor fortaleza en los momentos difíciles, y todo lo que hoy soy y logro, lleva tu huella. Espero que te sientas orgullosa de mí, porque cada paso que doy está inspirado en ti y en la gran mujer que eres.

A mi hermana, Karelys, por su apoyo, cariño y por estar ahí cuando más la necesitaba. Su apoyo ha sido un motor de motivación en mi camino.

A mi familia, por ser siempre mi red de apoyo. Gracias por su cariño, por creer en mí incluso cuando yo dudaba, y por enseñarme el valor de la unidad, el respeto y la resiliencia. Cada uno, desde su lugar, ha sido parte esencial de este logro.

A mis amigos, Darío, Brandon, Nicole, Jean, Davor y Melanie, gracias por su lealtad, por las palabras de ánimo y por compartir conmigo tanto los momentos difíciles como los de alegría. Su amistad ha sido un refugio invaluable.

A mis docentes, que con vocación y compromiso me guiaron en mi formación académica. Gracias por compartir su conocimiento y por fomentar en mí la pasión por aprender.

A mi abuela Juanita y mi madrina Carmen que aunque ya no están físicamente a mi lado, sé que están orgullosas de lo que he logrado y me bendicen siempre, siendo las estrellas más brillantes de mi cielo. Este logro también es por ellas, por su amor y sus enseñanzas que siguen acompañándome.

A todos los que, de alguna forma, aportaron a este proceso: gracias. Este trabajo no es solo mío, es el reflejo del amor, el apoyo y la confianza que me han brindado.

AGRADECIMIENTO

Quiero expresar mi más sincero agradecimiento a todas las personas e instituciones que hicieron posible la realización de este trabajo de investigación.

A mi tutora, la Ing. Ximena Quintana López, PHD, por su guía, paciencia y valiosos aportes durante el desarrollo de este proyecto. Su compromiso y conocimiento fueron fundamentales para mantener el rumbo y enriquecer el enfoque de esta investigación.

A los docentes de la Carrera de Ingeniería en Tecnologías de la Información, gracias por compartir conmigo no solo sus conocimientos, sino también su dedicación y vocación, que han sido pilares clave en mi formación académica y profesional.

A la Universidad Nacional de Chimborazo, por brindarme un espacio de crecimiento, acceso a recursos y una educación de calidad que me ha permitido enfrentar este reto con responsabilidad y preparación.

A mi familia, por su amor incondicional, su comprensión y su constante apoyo en cada etapa de este camino. Sin ustedes, este logro no habría sido posible.

Y a todas las personas que, de una forma u otra, aportaron a la culminación de este trabajo, les extiendo mi más profundo agradecimiento.

Índice General

CAPÍTULO I. INTRODUCCIÓN.....	14
1.1 Planteamiento del problema	14
1.2 Justificación.....	15
1.3 Formulación del Problema.....	16
1.4 Objetivos.....	16
CAPÍTULO II. MARCO TEÓRICO.....	17
2.1 Inteligencia Artificial y Análisis de Sentimientos.....	17
2.1.1 Aplicaciones de IA en el análisis de sentimientos.....	17
2.1.2 Importancia del análisis de sentimientos en redes sociales	17
2.2 Procesamiento de Lenguaje Natural (PLN).....	18
2.2.1 Técnicas clave de PLN	18
2.2.2 Aplicación del PLN en textos de Instagram	21
2.3 Algoritmos y modelos de análisis de sentimientos.....	22
2.3.1 Algoritmos de aprendizaje automático	22
2.3.2 Modelos basados en Transformers (BERT)	23
2.3.3 Comparativa de técnicas para el análisis de sentimientos	24
2.4 Desarrollo de Aplicaciones Web para Integración de IA	24
2.4.1 Tecnologías para el frontend y backend.....	25
2.4.2 Desarrollo de Aplicaciones Web para Integración de IA	26
2.5 Evaluación del Desempeño del Modelo de Análisis de Sentimientos	26
2.5.1 Principales métricas: precisión, recall, F1-score	26
2.5.2 Métodos de validación de modelos	27
CAPÍTULO III. METODOLOGÍA.....	28
3.1 Tipo de Investigación	28
3.2 Diseño de Investigación.....	28
3.3 Técnicas de recolección de datos.....	28
3.4 Población de estudio y tamaño de muestra.....	28
3.5 Métodos de análisis y procesamiento de datos.....	31
3.6 Identificación de variables.....	31
3.7 Operacionalización de variables.....	32
3.8 Metodología de desarrollo	33
Fase 1: Análisis inicial.....	33

Fase 2: Diseño del Prototipo.....	33
Fase 3: Implementación.....	35
Fase 4: Pruebas	39
CAPÍTULO IV. RESULTADOS Y DISCUSIÓN	43
4.1 Resultados.....	43
4.1.1 Resultado del Objetivo Específico de Investigación	43
4.1.2 Resultado del Objetivo Específico de Implementación.....	44
4.1.3 Resultado del Objetivo Específico de Evaluación.....	45
4.2 Discusión	46
4.2.1 Funcionamiento del sistema	46
4.2.2 Integración del sistema	46
4.2.3 Desempeño del modelo	46
CAPÍTULO V. CONCLUSIONES Y RECOMENDACIONES	48
5.1 Conclusiones.....	48
5.2 Recomendaciones	48
ANEXOS.....	53

ÍNDICE DE TABLAS

Tabla 1: Ejemplo de puntajes de los modelos de clasificación	24
Tabla 2: Distribución por categoría de sentimiento	30
Tabla 3: Operacionalización de variables	32
Tabla 4: Requerimientos funcionales del sistema	33
Tabla 5: Requerimientos no funcionales del sistema	33
Tabla 6: Homepage	36
Tabla 7: Dashboard	36
Tabla 8: Proceso de análisis de sentimiento	38
Tabla 9: Pruebas de funcionamiento	40
Tabla 10: Pruebas de desempeño del modelo	41
Tabla 11: Rangos de desempeño	43
Tabla 12: Comparación de modelos de análisis de sentimientos	44

ÍNDICE DE FIGURAS

Figura 1: Ejemplo de tokenización.....	19
Figura 2: Ejemplo de stemming	20
Figura 3: Ejemplo de lematización	20
Figura 4: Ejemplo de eliminación de stopwords.....	21
Figura 5: Arquitectura de Node.js	25
Figura 6: Diagrama de caso de uso	34
Figura 7: Diagrama de secuencia	34
Figura 8: Diagrama de componentes.....	35
Figura 9: Mapa de navegación	35
Figura 10: Homepage	39
Figura 11: Dashboard.....	39
Figura 12: Pruebas de integración.....	41
Figura 13: Matriz de confusión	42

RESUMEN

El presente trabajo de investigación tuvo como objetivo desarrollar una aplicación web para el análisis de sentimientos en publicaciones y comentarios de Instagram, utilizando técnicas avanzadas de inteligencia artificial y procesamiento del lenguaje natural. El propósito fue evaluar cómo el uso de modelos preentrenados basados en Transformers podía mejorar el desempeño del análisis frente a métodos tradicionales, aportando una herramienta funcional para la interpretación automática de opiniones en redes sociales.

Se utiliza una metodología mixta, con enfoque cualitativo que incluye la revisión bibliográfica sobre técnicas de inteligencia artificial aplicada al análisis de sentimientos y cuantitativa para la evaluación del desempeño del sistema en términos de precisión, recall y F1-score. Se implementó una arquitectura distribuida conformada por React.js en el frontend y Node.js en el backend, complementada con un script en Python encargado de ejecutar el modelo RoBERTuito, especializado en análisis de sentimientos en español. Para la extracción de información se utilizó Puppeteer con el complemento Stealth, lo que permitió automatizar la recopilación de publicaciones y comentarios de Instagram de manera dinámica y segura. Se realizaron pruebas funcionales, de integración y evaluación del desempeño.

Las pruebas mostraron que el sistema funcionó de manera correcta y que cada una de sus secciones se unió sin fallas. El modelo RoBERTuito alcanzó resultados mayores al 85% en métricas de desempeño como lo son la precisión, el recall y el F1-score. A pesar de esto, observó que el tiempo que el modelo necesitó para el procesamiento de cada publicación era elevando, esto debido al alto consumo de recursos computacionales necesarios para la extracción de la información.

Por último, la aplicación que se desarrolló mostró un alto desempeño al utilizar modelos de inteligencia artificial con bases en Transformers para la evaluación y etiquetado de sentimientos en redes sociales, lo que comprueba su eficacia al ser aplicada en entornos reales. Además se sugiere la incorporación de tecnologías contemporáneas de desarrollo web y modelos de aprendizaje profundo, dado que representa una alternativa eficiente y escalable. Para aumentar la rapidez del análisis sin comprometer la calidad de los resultados, se sugiere que el componente de extracción de datos sea optimizado a través de métodos que requieran menos recursos computacionales.

Palabras claves: Instagram, RoBERTuito, inteligencia artificial, análisis de sentimientos, aprendizaje profundo y procesamiento del lenguaje natural.

ABSTRACT

This research aimed to develop a web application for sentiment analysis in Instagram posts and comments, using advanced artificial intelligence and natural language processing techniques. The purpose was to evaluate how the use of pre-trained Transformers-based models could improve analysis performance compared to traditional methods, providing a functional tool for the automatic interpretation of opinions on social media.

A mixed-methods approach was used, with a qualitative focus that included a literature review of artificial intelligence techniques applied to sentiment analysis, and a quantitative approach to evaluate system performance in terms of accuracy, recall, and F1 score. A distributed architecture was implemented, consisting of React.js on the frontend and Node.js on the backend, complemented by a Python script that runs the RoBERTuito model, specialized in sentiment analysis in Spanish. Puppeteer with the Stealth plugin was used for data extraction, enabling dynamic, secure automation of Instagram post and comment collection. Functional, integration, and performance evaluation tests were conducted.

Tests showed that the system performed correctly and at high speed when using Transformer-based artificial intelligence models for sentiment analysis and labeling on social media. The RoBERTuito model achieved performance exceeding 85% across metrics such as accuracy, recall, and F1 score.

Keywords: Instagram, RoBERTuito, artificial intelligence, sentiment analysis, deep learning, and natural language processing.



Reviewed by:

Mgs. Sofia Freire Carrillo

ENGLISH PROFESSOR

C.C. 0604257881

CAPÍTULO I. INTRODUCCIÓN

La aparición de redes sociales ha creado una creciente necesidad de analizar el criterio y emociones de los usuarios. El análisis de las emociones en las redes sociales permite identificar modelos de significado y proporcionar las tendencias de comportamiento de los usuarios (Salgado Reyes & Trujillo Moreno, 2024). Este método se ha transformado en el instrumento más relevante para la toma de decisiones en diversos sectores (Pérez et al., 2021). Adicionalmente, la inteligencia artificial facilitó la optimización de los procesos de análisis y consiguió resultados más exactos y en un tiempo más breve.

La creación de programas para la web destinados a mirar lo que la gente siente en lugares como Instagram tiene dificultades de máquina y de cómo se hacen las cosas. Es fundamental tener una interfaz intuitiva y fácil de usar para optimizar notablemente la experiencia del usuario y, por ende, lograr resultados más claros y de mejor calidad (Intriago Camacho, 2023). Igualmente, para que la implementación de técnicas de aprendizaje automático sea eficaz, se necesita un manejo apropiado de la información con el fin de disminuir errores y aumentar la precisión (Plaza del Arco, 2024). En este contexto, es esencial escoger las características y estandarizar los datos para asegurar que el modelo funcione adecuadamente.

Se han llevado a cabo numerosas investigaciones que estudian la puesta en funcionamiento de modelos de lenguaje natural con el objetivo de potenciar las emociones en las plataformas sociales. (Rosero Gómez, 2022) asegura que al juntar la extracción de datos con el PLN, se logra hacer un examen más completo de la información al instante. Además, (García Riquero, 2023) demostró un sistema que utiliza la PLN para clasificar de manera automática los textos en las redes sociales, mostrando así su uso en los ámbitos empresarial y académico. Este estudio muestra lo útil que son estas técnicas ya que debido a su gran capacidad se pueden usar en muchos ámbitos distintos. El trabajo resalta esta habilidad y su uso es posible en varios entornos a los que apunta esta investigación.

1.1 Planteamiento del problema

La expansión de las redes sociales ha originado un volumen considerable de información generada por los usuarios, que incluyen publicaciones, comentarios, respuestas y mensajes en tiempo real. Como una de las plataformas de mayor importancia, Instagram acoge una amplia variedad de interacciones diarias que reflejan las emociones y perspectivas de sus usuarios respecto a múltiples temas. No obstante, el volumen y la rapidez con la que se produce este contenido complican su evaluación manual. Esto implica que numerosas compañías, generadores de contenido y entidades no consiguen detectar a tiempo las emociones y puntos de vista que se perciben en torno a sus marcas, productos o servicios.

Este reto tiene una serie de consecuencias. Primero que nada, si las compañías pasan por alto los comentarios o sugerencias positivas de sus clientes, podrían dejar de perfeccionar sus bienes o servicios. En segundo lugar, si las inquietudes o desavenencias no son identificadas a tiempo, hay un riesgo de un inconveniente relacionado con la reputación que podría haberse manejado con mayor eficacia utilizando la información correcta. Del mismo modo, los creadores de contenido o influencers tendrían un entendimiento más profundo de los

sentimientos de su público. Esto les proporcionaría la oportunidad de modificar su contenido para lograr que el efecto sea más importante.

Pese a que existen ciertas herramientas para el análisis de sentimientos en las redes sociales, como Twitter o Facebook, todavía no se han creado soluciones concretas y asequibles que sean efectivas con Instagram, teniendo en cuenta los rasgos particulares del tratamiento de datos de esta plataforma. Esto demuestra que es muy importantes contar con una aplicación que realice este tipo de análisis y muestre los resultados en tiempo real, de forma clara y sencilla de comprender. Esto permitiría a las personas tomar decisiones usando información sobre las emociones.

1.2 Justificación

El diseño de una plataforma en línea enfocada en el estudio de reacciones en las publicaciones y comentarios de Instagram es muy relevante en los ámbitos académico y práctico. Desde la óptica empresarial, es crucial que las compañías entiendan profundamente las emociones y perspectivas de sus clientes para reforzar su vínculo con ellos y enriquecer la experiencia del usuario. La capacidad de analizar automáticamente el sentimiento relacionado con una marca o producto puede asistir a las empresas en la modificación de sus estrategias de marketing, solucionar problemas antes de que se conviertan en crisis y, en última instancia, mejorar su competitividad en el mercado.

Desde el punto de vista de un grupo social, las investigaciones acerca de las emociones en Instagram pueden contribuir a que el entorno en línea sea más favorable y esperanzador. Para idear estrategias de intervención más efectivas que propicien una interacción digital más armónica, sería ventajoso identificar las emociones negativas, como el acoso en línea o el resentimiento, desde los primeros instantes.

Desde el punto de vista educativo, ha habido un avance importante en la inteligencia artificial aplicada, sobre todo en los campos vinculados a la comprensión del lenguaje humano. Se podrá desarrollar una herramienta en línea que no solamente estará a disposición en Instagram, sino también en otras plataformas que puedan surgir más adelante, por medio de la adopción de tecnologías nuevas, como modelos de escritura más sofisticados y la inteligencia artificial.

Finalmente, el proyecto puede tener un impacto en las decisiones que se basan en datos. La herramienta ayudará a los usuarios a mejorar sus interacciones en las redes sociales gracias a que brinda datos exactos y útiles; esto perfeccionará la comunicación y fortalecerá su vínculo con el público.

1.3 Formulación del Problema

¿Cómo el uso de técnicas avanzadas de inteligencia artificial puede incidir en el desempeño de una aplicación web para el análisis de sentimientos en publicaciones y comentarios de Instagram?

1.4 Objetivos

General

- Desarrollar una aplicación web para el análisis de sentimientos en publicaciones y comentarios de Instagram utilizando técnicas de inteligencia artificial.

Específicos

- Investigar algoritmos de análisis de sentimientos basados en inteligencia artificial, con énfasis en el procesamiento de texto en redes sociales, específicamente en publicaciones y comentarios de Instagram.
- Implementar una aplicación web para el análisis de sentimientos en Instagram, integrando técnicas de procesamiento de lenguaje natural y aprendizaje automático.
- Evaluar el desempeño de la aplicación para el análisis de sentimientos en publicaciones y comentarios de Instagram, utilizando métricas de rendimiento como precisión, recall y F1-score.

CAPÍTULO II. MARCO TEÓRICO

2.1 Inteligencia Artificial y Análisis de Sentimientos

La Inteligencia Artificial (IA) se refiere a la habilidad de las máquinas para aplicar algoritmos, adquirir conocimientos de los datos y emplear lo aprendido en la toma de decisiones de manera similar a la de un ser humano. (Albuja Sánchez & Guadalupe Almeida, 2022)

El propósito principal de la Inteligencia Artificial (IA) es trasladar el modo de pensar y razonar humanos a la computación. Se sugiere especialmente potenciar en la máquina la habilidad de percepción, el aprendizaje basado en la experiencia, la vinculación de conocimientos - que incluyen conocimientos abstractos o conceptos - y la resolución de dificultades. (Alastruey, 2021)

La Inteligencia Artificial (IA) ha marcado un punto de inflexión en la historia de la informática incluyendo su creciente implementación para el análisis y procesamiento de datos y su inclusión en diferentes redes sociales.

El análisis de sentimientos es un campo de investigación en constante desarrollo dentro de la minería de textos, consiste en el tratamiento computacional de opiniones, sentimientos y subjetividad en un texto. (Walaa et al., 2014)

2.1.1 Aplicaciones de IA en el análisis de sentimientos

El análisis de sentimientos (también conocido como minería de opinión) es un método de procesamiento del lenguaje natural que busca reconocer y categorizar las emociones y puntos de vista manifestados en los textos de forma automática. Se trata de establecer la polaridad de un texto, es decir, categorizar las emociones en positivas, negativas o neutras, o identificar sus emociones, tal como las 6 emociones fundamentales de Ekman, que son: alegría, tristeza, temor, ira, sorpresa y asco. (Muñoz Cano, 2023)

La habilidad de la Inteligencia Artificial para llevar a cabo análisis de emociones en tiempo real ha jugado un papel crucial en el sector de las redes sociales. La plataforma social X, por ejemplo, emplea algoritmos de procesamiento de lenguaje natural para examinar los tweets y comprender las emociones y puntos de vista de los usuarios.

Esta información actualizada no solo asiste a la plataforma en entender la visión del público respecto a eventos y asuntos, sino que también posibilita respuestas flexibles y a tiempo. Los algoritmos para el análisis de sentimientos de X manejan más de 500 millones de tuits al día, ofreciendo una visión en tiempo real de la opinión pública. (Calle García et al., 2023)

2.1.2 Importancia del análisis de sentimientos en redes sociales

En años recientes, el crecimiento de las redes sociales ha facilitado que los usuarios expresen su punto de vista sobre cualquier asunto o producto, considerándose esta más genuina y consistente con lo que sería a través de una encuesta. La disponibilidad de una fuente de información tan abundante constituye una oportunidad para los interesados; no obstante,

también supone una dificultad, debido a los procedimientos que conlleva su análisis y la fiabilidad que ofrecen las herramientas especializadas en ello. Por lo tanto, se requieren soluciones que distingan de forma más efectiva las opiniones, las cuanticen de manera exacta y que su aplicación no suponga un mayor desafío.

De esta necesidad emergió el análisis de sentimientos, entendido como el conjunto de métodos computacionales para la obtención, categorización, entendimiento y valoración de las emociones producidos por los usuarios. (Aleman Viteri, 2021)

El análisis de sentimientos, una rama del procesamiento del lenguaje natural, se centra en la identificación y categorización automáticas de las emociones y sentimientos expresados en textos escritos. Con el crecimiento exponencial de las redes sociales, la disponibilidad de opiniones y sentimientos públicos ha aumentado, convirtiendo el análisis de sentimientos en una herramienta crucial para comprender el sentir público en diversos ámbitos como los negocios, la política, entre otros. (Kian Long Tan & Kian Ming, 2023)

2.2 Procesamiento de Lenguaje Natural (PLN)

El lenguaje se define como un medio mediante el cual los seres humanos pueden comunicarse y manifestar racioamiento, este medio se basa en la vinculación de signos con determinados significados. El lenguaje emplea instrumentos como la escritura, las señales y la voz para establecer comunicación. En este punto, se distinguen dos clases de lenguaje. Por un lado, el lenguaje natural, donde hallamos lo que a menudo denominamos idiomas como el inglés, español, alemán, entre otros, estos lenguajes están en constante evolución sin considerar las normas que los rigen. Por otra parte, los lenguajes formales que se ubican en áreas como la matemática, la lógica o la programación, están estrictamente adheridos a normas preestablecidas.

El Procesamiento Natural del Lenguaje (PNL) es la disciplina que aspira a comprender el funcionamiento del lenguaje, su estructura, la creación de nuevo lenguaje, y todas las actividades vinculadas con el manejo del lenguaje. Dentro de estas actividades se incluyen la creación de nuevo contenido, la traducción de un idioma a otro, la formulación de preguntas y respuestas, la creación de resumen, chatbots, entre otros. (Beltrán & Rodríguez, 2021)

El PLN ha pasado de aprender representaciones y diseñar arquitecturas específicas de tareas, al uso de preentrenamiento y arquitecturas independientes de la tarea. Este cambio ha dado lugar a un progreso sustancial en muchas tareas desafiantes de PLN, como comprensión lectora, respuesta a preguntas y análisis de textos. (Brown et al., 2020)

2.2.1 Técnicas clave de PLN

- **Tokenización**

Una de las estrategias de PLN más empleadas es la tokenización, que implica dividir el texto en palabras o conjuntos de palabras, conocidos como tokens. Todo esto se hace para simplificar su posterior procesamiento. (Muñoz Cano, 2023)

Como puede apreciarse en la figura 1, la forma en la que se realiza el proceso de tokenización de una frase la cual se procesa y pasa a convertirse en tokens.

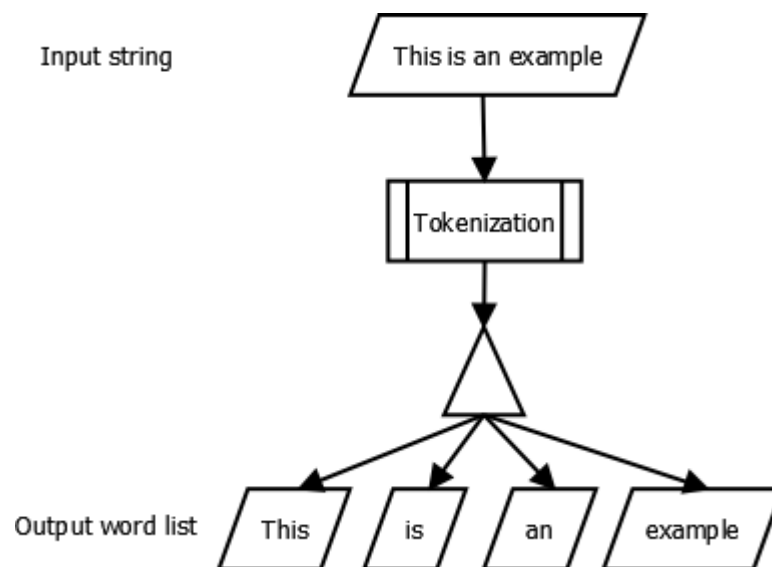


Figura 1: Ejemplo de tokenización
Fuente: (Muñoz Cano, 2023)

- **Stemming**

El Stemming implica reducir las palabras a su raíz, tal como señala su nombre en inglés (stem), de esta manera, acotamos aún más el idioma y será más sencillo su identificación posterior de emociones. A través de este método, identificamos problemas como la sobre-stemming y la sub-stemming.

El primero ocurre cuando se hallan palabras con la misma raíz que deberían poseer raíces distintas, ya que no poseen ninguna relación entre sí. El segundo problema sucede cuando dos palabras que deberían tener la misma raíz tienen raíces diferentes. (Muñoz Cano, 2023)

A continuación, como se evidencia en la figura 2, el proceso de stemming reduce diferentes palabras a una palabra raíz.

Stemming

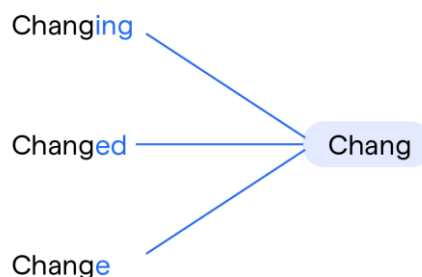


Figura 2: Ejemplo de stemming
Fuente: (Chandu Aki, 2024)

- **Lematización**

Es una técnica muy parecida al stemming, aunque en esta situación, se limitan sus palabras a su forma fundamental, a su lema, teniendo en cuenta el contexto gramatical en el que se ubica esa palabra.

Considerando esto, es importante entender que una misma palabra posea un lema diferente dependiendo del contexto en el que se encuentre. (Muñoz Cano, 2023)

En la figura 3, se puede observar como a pesar de que la lematización es un proceso similar al stemming, este depende más del contexto para reducir las palabras a su lema.

Lemmatization

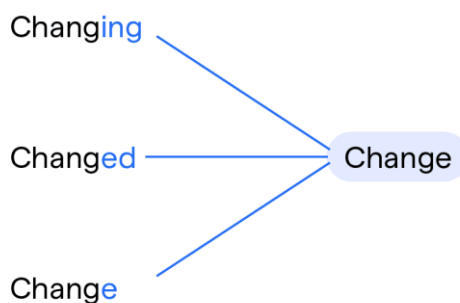


Figura 3: Ejemplo de lematización
Fuente: (BotPenguin, 2025)

- **Eliminación de stopwords**

La eliminación de stopwords consiste en deshacerse de términos comunes que carecen de valor informativo, como preposiciones o artículos, por ejemplo, "el" y "de". Usualmente se recurre a listas ya establecidas que incluyen estas palabras clave, pero

también es posible elaborar una lista a medida de acuerdo con las exigencias. (Muñoz Cano, 2023)

La figura 4 ilustra la identificación de stopwords en una frase, las cuales se procede a suprimir debido a que estas no proporcionan información relevante para el análisis.

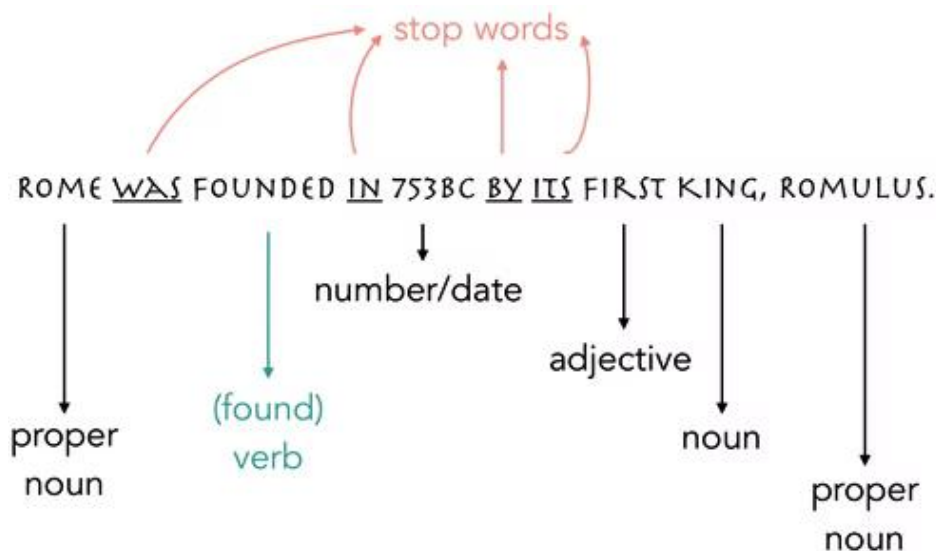


Figura 4: Ejemplo de eliminación de stopwords
Fuente: (GetApp, 2022)

2.2.2 Aplicación del PLN en textos de Instagram

El surgimiento y crecimiento progresivo de los medios sociales ha favorecido la generación de numerosas aplicaciones relacionadas con sus contenidos: las demandas analíticas en los ámbitos de la industria, medios de comunicación y periodismo, salud, política, seguridad, entre otros, demandan habilidades para manejar grandes volúmenes de datos diversos. La industria se enfoca en potenciar su inteligencia empresarial, imagen de la empresa, dedicación al cliente, optimización de los servicios al cliente, marketing digital, pronósticos del mercado, sugerencias de productos o reputación. El estudio de las redes sociales facilita la comprensión de situaciones y el análisis de grupos de personas con intereses y puntos de vista similares. (Porta Zamorano & Sancho Sánchez, 2021)

Hoy en día, el análisis de texto se lleva a cabo de forma automática, donde la intervención de las computadoras se fundamenta en que el ordenador asimile estas características de los textos. Por lo tanto, la metodología computacional se encarga del análisis de textos. Este proceso se conoce como Procesamiento del Lenguaje Natural y se emplea para identificar palabras clave dentro de un conjunto de documentos, con el objetivo de identificar palabras que se repitan en esa sección. (Celi Parraga et al., 2021)

2.3 Algoritmos y modelos de análisis de sentimientos

Hoy en día, uno de los métodos más populares para analizar las conductas emocionales en los textos es utilizando el aprendizaje automático, conocido en inglés como machine learning. Este subcampo de la ciencia informática y la inteligencia artificial se enfoca en identificar patrones en los datos para generar algoritmos inteligentes capaces de aprender sin necesidad de programación basada en reglas; estos algoritmos poseen la habilidad de progresar de manera autónoma con el transcurso del tiempo y se clasifican en dos clases de aprendizaje, el aprendizaje supervisado y el aprendizaje no supervisado. (Sánchez DelaCruz et al., 2020)

2.3.1 Algoritmos de aprendizaje automático

- **SVM**

Es un modelo de educación supervisada enfocado en la clasificación y el análisis de regresiones. Las características de los datos clasificados se ilustran con un vector de n dimensiones que sitúa cada entrada del dataset como un punto en un espacio. El algoritmo determina un hiperplano que separa de la mejor manera posible los puntos etiquetados en el conjunto de entrenamiento.

Una vez establecido, es posible anticipar una nueva entrada al situar su representación en el espacio y determinar en qué parte del hiperplano se ubicó. Considerando un grupo de entrenamiento, $(X_1, Y_1) \dots (X_n, Y_n)$, $X_i \in R_n$, se establece el hiperplano como $w \cdot x + b = 0$, donde w es el vector de pesos, x simboliza la entrada o entrada, y b simboliza el sesgo o bias. w y b deben cumplir con las siguientes inequidades, y si $y_i = 1$, entonces $w \cdot x_i + b = 1$. La finalidad de este algoritmo se centra en determinar los valores de w y b que permitan la separación óptima del conjunto de datos.

El entrenamiento del modelo de SVM, ofrece las siguientes ventajas: eficacia en espacios vectoriales de múltiples dimensiones; emplea un grupo reducido de puntos en el espacio, lo que simplifica su entrenamiento; y se tiene la opción de especificar funciones de Kernel. (Lovera & Cardinale, 2023)

- **Naive Bayes**

Son algoritmos de categorización fundamentados en el teorema de Bayes, utilizados en los algoritmos de clasificación. Los modelos "Naive" presuponen la autonomía entre las diferentes variables empleadas en la predicción, lo que significa que una característica específica en un conjunto de datos no tiene relación con cualquier otra característica que pudiera existir. Es el cálculo de una probabilidad a posteriori fundamentada en unas probabilidades previamente conocidas (anteriores). (Patricio Guisado & Berlanga de Jesús, 2020)

Este clasificador pertenece a un conjunto de clasificadores probabilísticos basados en la suposición de que todos los eventos son independientes de una variable, esto quiere decir que el efecto del valor de un predictor en una clase es independiente de

los valores de otros predictores, esta suposición se llama independencia condicional de clase. (Lovera & Cardinale, 2023)

2.3.2 Modelos basados en Transformers (BERT)

Los modelos Transformer han representado la más reciente gran revolución en el procesamiento del lenguaje natural. Desde el lanzamiento de la arquitectura original en 2017, se han creado una amplia gama de modelos basados en Transformer. (Palomino Bravo, 2023)

La aparición de modelos de lenguaje preentrenados basados en Transformers ha mejorado notablemente el acceso a modelos de alto rendimiento para el usuario medio. (José et al., 2023) (Traducción propia)

- **BERT (Bidirectional Encoder Representations from Transformers)**

Google desarrolló un modelo de lenguaje pre-entrenado en 2018. Lo que BERT logra es pre-entrenar un modelo de lenguaje en extensos corpus de texto (3.300 millones de palabras) sin etiquetar, con el objetivo de instruir al modelo en la predicción de las palabras ausentes en una secuencia de texto proporcionada. En el entrenamiento, BERT adquiere la habilidad de recoger la información contextual de las palabras en una secuencia, lo que facilita que el modelo entienda de manera más efectiva el sentido de las palabras en su contexto. (Palomino Bravo, 2023)

- **RoBERTa:**

Es un modelo de lenguaje preentrenado creado por Facebook AI Research en 2019.

El equipo investigativo detectó que BERT no contaba con la cantidad adecuada de información. Por lo tanto, la principal innovación de RoBERTa es que emplea un conjunto de datos de entrenamiento más grande, específicamente, 160 GB de texto en vez de los 16 GB inicialmente utilizados para el entrenamiento de BERT. (Palomino Bravo, 2023)

- **ALBERT**

Google AI Language desarrolló A Lite BERT en 2019. La mayor innovación que presenta ALBERT es su mayor eficiencia en cuanto a recursos informáticos y datos de entrenamiento, aunque consigue un desempeño comparable o incluso superior a otros modelos de lenguaje más amplios y costosos, como BERT y RoBERTa. (Palomino Bravo, 2023)

- **BETO**

BERT también cuenta con una versión en español denominada BETO. Este último logra una representación cuantitativa del texto, aunque con un contexto y significado distintos debido al idioma empleado. (Guzmán Landa et al., 2023)

2.3.3 Comparativa de técnicas para el análisis de sentimientos

En el estudio comparativo de las técnicas para el análisis de sentimientos Naive Bayes, Random Forest, Regresión Logística, SVM, LSTM + Word2Vec y BERT (BETO), Las dos técnicas más recientes lograron los resultados más favorables, aproximadamente un 7% superiores a las primeras cuatro, a pesar de que no existen diferencias significativas entre ambas en este caso. Respecto al preprocesamiento de los datos, se notó que la supresión de Stop Words, tanto del diccionario inicial de la librería NLTK como el modificado, no produjo resultados más favorables, sino que, en cambio, redujo su eficiencia.

En la literatura contemporánea, se encuentran varios estudios de clasificación de comentarios de películas redactados en inglés [28, 29, 30], en los cuales se consiguió un resultado de Accuracy entre un 85% y un 94%. Sin embargo, en el caso de estudio, se logró un valor del 83%, es decir, entre un 2% y un 11% menos. Esta discrepancia puede originarse por diversas razones: variaciones inherentes al idioma, preentrenamiento con un corpus de menor tamaño, variaciones en el grado de informalidad del dialecto coloquial empleado, o incluso, un mejor ajuste de ciertos hiperparámetros. (Rosenbrock et al., 2021)

A continuación, en la Tabla 1 se muestra un ejemplo de los parámetros Accuracy, Precision, Recall y F1-Score, medidos en el artículo "Técnicas de Análisis de Sentimientos Aplicadas a la Valoración de Opiniones en el Lenguaje Español"

Tabla 1: Ejemplo de puntajes de los modelos de clasificación

Modelos	Accuracy	Precision	Recall	F1-Score
Naive Bayes	0.80	0.80	0.81	0.81
Random Forest	0.80	0.82	0.77	0.79
Regresión logística	0.80	0.80	0.80	0.80
SVM	0.79	0.79	0.79	0.79
LSTM + Word2Vec	0.81	0.85	0.88	0.87
Bert (Beto)	0.83	0.85	0.91	0.88

Fuente: (Rosenbrock et al., 2021)

2.4 Desarrollo de Aplicaciones Web para Integración de IA

Cuando se diseña una aplicación web, se deben considerar varios aspectos, dado que el diseño de la aplicación es esencial en cualquier proyecto, pues se establece la estructura, el funcionamiento y la usabilidad de esta. En esta situación, una aplicación web adecuadamente estructurada puede asistir a los usuarios a entender de forma más efectiva los resultados del análisis de emociones. (Muñoz Cano, 2023)

2.4.1 Tecnologías para el frontend y backend

- **React.js**

React es una librería de Javascript de código abierto utilizada para la creación de interfaces de usuario. Jordan Walke, ingeniero de software de Facebook, desarrolló React. Fue lanzado inicialmente en 2011 por Facebook y posteriormente en 2012 por Instagram.

Además, nos facilita la creación de UIs interactivas para aplicaciones Web sencillas o complejas, permitiéndonos modificar la información presentada sin tener que recargar la página en su totalidad. Por lo tanto, se presenta el concepto de Componente.

Los componentes posibilitan dividir la interfaz de usuario en componentes autónomos, reutilizables y reflexionar sobre cada componente de manera individual. Los elementos pueden hacer referencia a otros elementos en su salida. Esto nos brinda la posibilidad de emplear la misma abstracción de componente para cualquier nivel de precisión. (Migliorata & Dahl, 2020)

- **Node.js**

La implementación de NodeJS proporciona ciertos beneficios al crear una aplicación web, los más destacados son: Rendimiento, al incorporar tecnologías como NodeJS en nuestras aplicaciones web, facilitamos la escalabilidad de estas aplicaciones desarrolladas y su alto rendimiento al ser utilizadas por un gran número de usuarios. NodeJS facilita la distribución de código entre el cliente y el servidor, dado que emplea JavaScript tanto en el frontend del cliente, que es fundamentalmente el frontend, como en el backend del servidor. (Cardona Amaya)

A continuación, en la figura 5, se puede observar el funcionamiento de la arquitectura de Node.js.

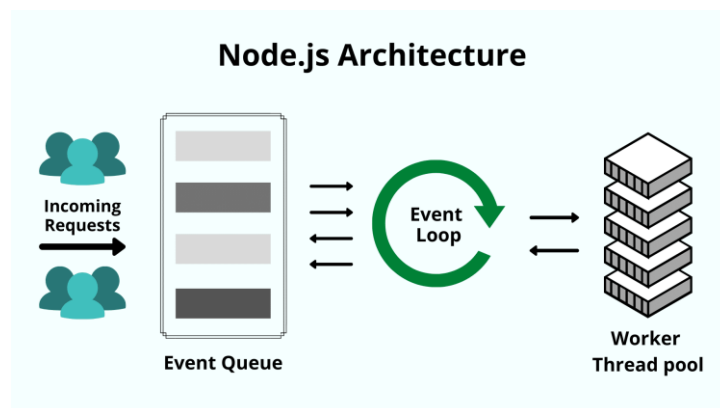


Figura 5: Arquitectura de Node.js
Fuente: (Kinsta, 2023)

2.4.2 Desarrollo de Aplicaciones Web para Integración de IA

Es esencial garantizar unos ambientes de ejecución similares al ambiente de desarrollo para el adecuado desempeño de los modelos creados.

La implementación de modelos puede tornarse aún más complicada si, en una misma plataforma, se requiere ejecutar más de un modelo al mismo tiempo. En estas situaciones, las variadas necesidades de dependencias en sus diferentes ediciones pueden generar conflictos e incompatibilidades al no ser factible separar diferentes versiones de una misma dependencia del sistema.

En el pasado, esta complicada labor ha requerido una gran cantidad de tiempo y esfuerzo de los expertos responsables de estos avances; no obstante, en los años recientes, hemos observado la aparición de tecnologías de contenerización que pueden emplearse para solucionar este problema de manera sencilla y eficaz.

Estas tecnologías, utilizando los denominados "contenedores", facilitan la encapsulación del código y todas sus dependencias en un artefacto que puede ser compartido y desplegado de manera sencilla y independiente en prácticamente cualquier plataforma que pueda usar esta tecnología. Este dispositivo puede incluir los modelos de aprendizaje automático y sus respectivos dispositivos, los ficheros de configuración, las dependencias de código y las dependencias del sistema que el proyecto necesite, preparado para su ejecución sin requerir ningún procedimiento adicional de instalación o configuración. Además, dado que no son sistemas de virtualización, no se aplican sanciones de rendimiento informática con su implementación. (Valderrama Santiago, 2021)

Previo a su implementación en la producción, estos modelos ejecutables requieren un proceso de validación inicial que asegure su idoneidad, corrección y rendimiento óptimo. Pese a la valoración de precisión y fiabilidad efectuada en fases anteriores, los modelos finales pueden cometer errores en su ejecución y mostrar comportamientos no deseados en determinadas circunstancias. De acuerdo con el contexto de aplicación, estas equivocaciones pueden provocar un impacto significativo y conllevar riesgos y daños de gran envergadura. Estos riesgos pueden ser de índole financiera, legal, de protección o de reputación, entre otros. (Vakaruk, 2023)

2.5 Evaluación del Desempeño del Modelo de Análisis de Sentimientos

El desempeño de los modelos léxicos se mide a través de indicadores como la exactitud, el reconocimiento y el puntaje F1, en particular este último, dado que mide la balanza entre los resultados positivos y negativos, aspecto esencial para el análisis de las emociones. (Lozano González, 2025)

2.5.1 Principales métricas: precisión, recall, F1-score

Es crucial entender que la precisión determina la proporción de positivos auténticos en relación con el total de positivos estimados, mientras que el recall (o sensibilidad) mide la habilidad del modelo para reconocer todos los casos de positivos verdaderos. Finalmente, el

F1-Score simboliza el promedio armónico de la precisión y el recall, proporcionando un equilibrio entre los dos. (Campos Sánchez y otros, 2024)

2.5.2 Métodos de validación de modelos

Los indicadores más empleados en la actualidad para valorar el rendimiento de modelos de clasificación son: la matriz de confusión, la medida de F1 y la exactitud. (Cedeno Moreno & Vargas Lombardo, 2020)

En contraposición, los métodos de validación cruzada implican segmentar el conjunto de datos de manera aleatoria, y luego asignarlos y reasignarlos a los grupos de entrenamiento, validación y prueba. (Martín Climenta & Moreno García, 2022)

Previo a su despliegue en producción, estos modelos ejecutables necesitan pasar por un proceso de validación preliminar que garantice su idoneidad, rectificación y óptimo desempeño. A pesar de la evaluación de exactitud y confiabilidad realizada en etapas previas, los modelos finales pueden tener fallos en su implementación y presentar comportamientos indeseables en ciertas situaciones. Según el contexto de aplicación, estos fallos pueden generar un gran efecto y representar riesgos y perjuicios de gran magnitud. Estos riesgos pueden ser de naturaleza financiera, jurídica, de seguridad o de reputación, entre otros. (Valderrama Santiago, 2021)

CAPÍTULO III. METODOLOGÍA

3.1 Tipo de Investigación

Se adoptó una metodología mixta, combinando enfoques cualitativos y cuantitativos. La investigación cualitativa incluyó una revisión bibliográfica exhaustiva sobre técnicas de inteligencia artificial aplicadas al análisis de sentimientos. La investigación cuantitativa evaluó el desempeño de estas técnicas mediante pruebas empíricas y métricas estándares como precisión, recall y F1-score.

3.2 Diseño de Investigación

En el presente proyecto de investigación se adoptó un diseño bibliográfico-aplicado. Inicialmente, se ejecutó una revisión bibliográfica de trabajos de investigación, tesis, artículos y libros afines al análisis de sentimientos y procesamiento de lenguaje natural, así como de modelos preentrenados como BERT y su versión al español BETO.

También se adoptó un diseño aplicado, mediante el cual se desarrolló una aplicación web en la que convergen el análisis de sentimientos y técnicas de procesamiento de lenguaje natural, la cual fue puesta a prueba a través del análisis de publicaciones y comentarios de Instagram.

3.3 Técnicas de recolección de datos

Se utiliza la técnica de revisión bibliográfica para la identificación de algoritmos relevantes en el análisis de sentimientos aplicado a redes sociales.

Se utiliza la técnica de recolección de datos Web Scraping para la recolección de datos textuales (publicaciones y comentarios) desde Instagram asegurando cumplimiento ético.

3.4 Población de estudio y tamaño de muestra

- **Población de estudio**

La población en este estudio se refiere al total de publicaciones y comentarios disponibles en Instagram dentro del período de análisis (último año), que incluye contenido de usuarios regulares, influenciadores y marcas.

Con billones de publicaciones y comentarios, la cifra de usuarios de Instagram es muy alta e indefinida. No obstante, con propósitos estadísticos y para determinar el tamaño de la muestra, se suele suponer que la población es infinita (mayor a 100,000 elementos), lo cual justifica el empleo de la Fórmula 1.

El contenido que producen los usuarios de Instagram se incluye en sus comentarios y mensajes:

- **Usuarios regulares:** individuos que participan en la plataforma sin propósitos comerciales y cuyos niveles de alcance son limitados.
 - Número de seguidores inferior a 10000.
 - Perfil que no poseen verificación.

- Publicaciones de contexto diario (imágenes personales, material no comercial)
- **Influenciadores:** individuos que producen contenido de gran alcance dirigido a públicos extensos o de temas concretos.
 - Cantidad de seguidores que supera los 10,000.
 - Un perfil que tenga o no tenga verificación.
 - Publicaciones con un tema específico y/o de índole comercial.
 - Gran tasa de interacciones (me gusta, comentarios, compartidos)
- **Marcas:** perfiles corporativos, comerciales o institucionales que simbolizan empresas, productos, servicios o proyectos.
 - Etiqueta determinada por la plataforma (empresa, comercio, servicio, etcétera).
 - Contenido mayormente de tipo informativo, promocional o comercial.
- **Tamaño de muestra**

Se obtendrá un grupo de datos balanceado por medio de una muestra que represente cada tipo de emoción (neutral, positiva y negativa).

Distribución por tipo de usuario:

- Usuarios regulares: 50%
- Influenciadores: 30%
- Marcas: 20%
- Nivel de confianza: 95%
- Margen de error: 5%
- Proporción esperada de la población (p): 50%

$$Tamaño\ de\ Muestra = \frac{Z^2 p(1-p)}{e^2}$$

Fórmula 1: Tamaño muestral de Cochran

Donde:

- $Z = 1.96$ (valor Z para un 95% de confianza).
- $p = 0.5$ (proporción esperada de la población).
- $e = 0.05$ (margen de error).

Se aconseja utilizar al menos 385 comentarios y publicaciones para asegurar que el margen de error sea del 5 % y el nivel de confianza, del 95 %.

Para distribuir la muestra de 385 publicaciones y comentarios, vamos a segmentarla en función de:

- Tipo de usuario (Usuarios regulares, Influenciadores, Marcas).
- Categoría de sentimiento (Positivo, Negativo, Neutral).
- Usuarios regulares: 50% (192 muestras)
- Influenciadores: 30% (116 muestras)
- Marcas: 20% (77 muestras)
- **Distribución por categoría de sentimiento**

Dividimos cada grupo en tres categorías de sentimiento (Positivo, Negativo y Neutral)

- Positivo: 33%
- Negativo: 33%
- Neutral: 33%

En la tabla 2 siguiente se muestra la distribución por categoría de sentimiento y tipos de usuarios para esta investigación.

Tabla 2: Distribución por categoría de sentimiento				
TIPO DE USUARIO	TOTAL DE MUESTRAS	POSITIVO 33%	NEGATIVO 33%	NEUTRAL 33%
USUARIOS REGULARES	192	64	64	64
INFLUENCIADORES	116	39	39	38
MARCAS	77	26	26	25
TOTAL	385	129	129	127

- **Representatividad y significancia estadística**

Para garantizar la representatividad de los datos y la significancia estadística de los resultados, se aplicó una muestra estratificada de 385 publicaciones y comentarios de Instagram, calculada con un nivel de confianza del 95 % y un margen de error del 5 %. La estratificación se realizó según el tipo de usuario (regular, influenciador y marca) y la categoría de sentimiento (positivo, negativo y neutral), lo que permitió cubrir de manera equilibrada los distintos tipos de interacciones que se presentan en la plataforma. Este enfoque asegura que los resultados obtenidos no dependan de un

grupo específico de usuarios, sino que reflejen tendencias generales del comportamiento emocional en Instagram. Además, la validación de las métricas del modelo (precisión, recall y F1-score) se realizó utilizando una muestra independiente etiquetada manualmente, lo que refuerza la fiabilidad de los resultados y su significancia estadística dentro del contexto del análisis de sentimientos en español.

3.5 Métodos de análisis y procesamiento de datos

- **Métodos de análisis**

- Implementación de algoritmos de PLN y machine learning.
- Evaluación de los resultados a través de métricas de rendimiento, como F1-score, el recall y la precisión.

- **Procesamiento de Datos**

- Obtención y depuración de datos a partir de Instagram.
- Clasificación de sentimientos (positivos, negativos o neutros) por medio de modelos entrenados.
- Generación de insights y visualización de los resultados.

3.6 Identificación de variables

- **Variable dependiente**

Desempeño de la aplicación en la identificación y clasificación de sentimientos en publicaciones y comentarios de Instagram.

- **Variable independiente**

Aplicación web para el análisis de sentimientos en publicaciones y comentarios de Instagram.

3.7 Operacionalización de variables

A continuación, la tabla 3, presenta la operacionalización de variables.

Tabla 3: Operacionalización de variables

PROBLEMA	TEMA	OBJETIVOS	VARIABLES	CONCEPTUALIZACION	DIMENSION	INDICADORES
¿Cómo el uso de técnicas avanzadas de inteligencia artificial puede incidir en el desempeño de una aplicación web para el análisis de sentimientos en publicaciones y comentarios de Instagram?	Desarrollo de una aplicación web para el análisis de sentimientos en publicaciones y comentarios de Instagram utilizando técnicas de IA	GENERAL	INDEPENDIENTE	El análisis de sentimientos es el proceso de identificar y clasificar emociones en textos mediante procesamiento de lenguaje natural y aprendizaje automático.	Análisis de sentimientos (positivo, negativo, neutro).	<ul style="list-style-type: none"> Número de publicaciones y comentarios procesados por la aplicación. Cantidad de usuarios activos que usan la aplicación. Disponibilidad del sistema.
		Desarrollar una aplicación web para el análisis de sentimientos en publicaciones y comentarios de Instagram utilizando técnicas de inteligencia artificial.	Aplicación web para el análisis de sentimientos en publicaciones y comentarios de Instagram.			
		ESPECIFICOS	DEPENDIENTE	Uso de modelos de IA avanzados para interpretar comentarios y publicaciones en redes sociales.	Calidad del software	<ul style="list-style-type: none"> Precisión Recall F1-Score
		<ul style="list-style-type: none"> Investigar técnicas y algoritmos de análisis de sentimientos basados en inteligencia artificial, con énfasis en el procesamiento de texto en redes sociales, específicamente en publicaciones y comentarios de Instagram. Implementar una aplicación web para el análisis de sentimientos en Instagram, integrando técnicas de procesamiento de lenguaje natural y aprendizaje automático. Evaluar el desempeño de la aplicación para el análisis de sentimientos en publicaciones y comentarios de Instagram, utilizando métricas de rendimiento como precisión, recall y F1-score. 	Desempeño de la aplicación en la identificación y clasificación de sentimientos en publicaciones y comentarios de Instagram.			

3.8 Metodología de desarrollo

Para este trabajo de investigación, se optó por la implementación de la metodología de prototipado evolutivo, esto debido a que esta metodología se caracteriza por el desarrollo progresivo de sistemas funcionales en los que se integran nuevas funciones, se ajustan módulos y se valida cómo se comporta el sistema, todo esto con la finalidad de crear un producto final funcional a través de la retroalimentación proporcionada por los usuarios.

Fase 1: Análisis inicial

En la fase de análisis inicial se realizó un estudio del problema, los objetivos que debía cumplir el sistema, los potenciales usuarios y las funcionalidad principales que se debían implementar en la aplicación, así como la determinación de las diferentes tecnologías que se utilizaron para su desarrollo.

A continuación, en la tabla 4 se detallan los requerimientos funcionales de la aplicación, recabados en la fase de análisis inicial.

Tabla 4: Requerimientos funcionales del sistema

Nº	Definición del requerimiento no funcional
RF1	La aplicación debe permitir a los usuarios ingresar una URL de una publicación pública de Instagram
RF2	La aplicación debe extraer de la URL facilitada por el usuario, el texto de la publicación y los comentarios
RF3	La aplicación debe analizar el sentimiento del texto de la publicación mediante un modelo de IA
RF4	La aplicación debe analizar el sentimiento los comentarios de la publicación (todos o un número definido)
RF5	La aplicación debe clasificar los resultados como positivos, negativos o neutros.
RF6	La aplicación debe mostrar los resultados del análisis de la publicación
RF7	La aplicación debe mostrar los resultados del análisis de cada comentario de la publicación (todos o un número definido)
RF8	La aplicación debe mostrar mediante un gráfico, los resultados del análisis de manera general.

La Tabla 6 mostrada a continuación, presenta los requisitos no funcionales de la aplicación.

Tabla 5: Requerimientos no funcionales del sistema

Nº	Requerimiento	Definición del requerimiento funcional
RNF1	Usabilidad	La plataforma tiene que ser clara y sencilla de navegar.
RNF2	Rendimiento	El reconocimiento de emociones tiene que hacerse en menos de diez segundos.
RNF3	Seguridad	El software tiene que proteger los datos de los usuarios y evitar el registro de contraseñas.
RNF4	Compatibilidad	La herramienta tiene que operar correctamente en los navegadores actuales.
RNF5	Escalabilidad	La herramienta debe ser desarrollada para que se le puedan hacer actualizaciones o ajustes más adelante.
RNF6	Accesibilidad	La plataforma debe adherirse a normativas fundamentales de accesibilidad.
RNF7	Mantenibilidad	El código debe estar organizado para permitir mejoras o alteraciones en el modelo de inteligencia artificial en el futuro.

Fase 2: Diseño del Prototipo

Durante la etapa de diseño del prototipo, se establecieron las características estéticas y lógicas de la aplicación. Esto incluye la estructura del sistema, los casos de uso y el flujo que toman los datos, es decir, una mezcla entre el desarrollo operacional y la interacción con los usuarios.

Diagrama de caso de uso

En la Figura 6 se puede observar el proceso de uso de la aplicación por parte del usuario y el funcionamiento general de esta última para el análisis de sentimientos y la exhibición de resultados.

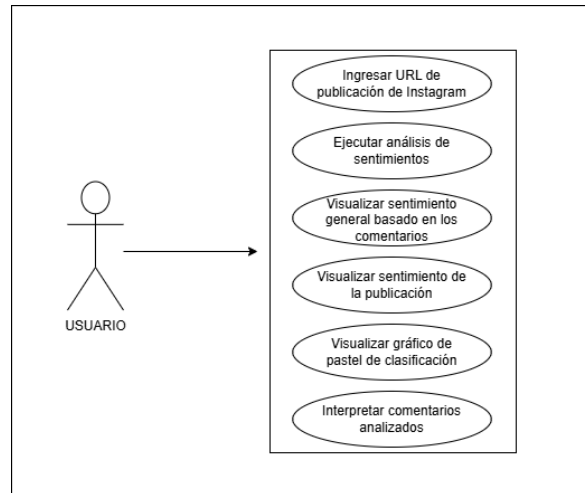


Figura 6: Diagrama de caso de uso

Diagrama de secuencia

La figura 7 muestra el flujo de los procesos que se llevan a cabo entre los diferentes componentes del sistema de manera cronológica.

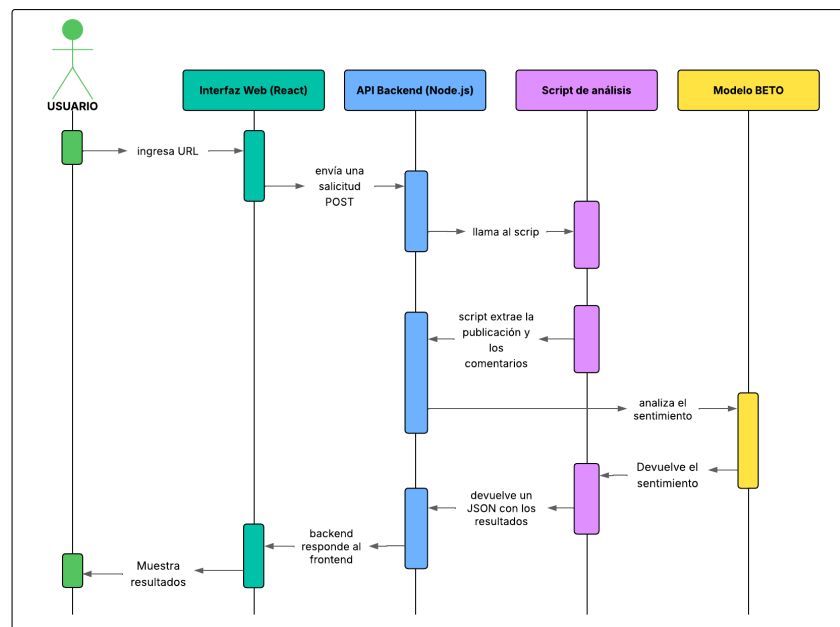


Figura 7: Diagrama de secuencia

Diagrama de componentes

La figura 8 muestra cómo, en cuanto a elementos técnicos, está organizado el sistema. Esto incluye las tecnologías empleadas, definiendo su lugar en el flujo y la interacción existente entre las mismas, evidenciando la estructura integral de la solución.

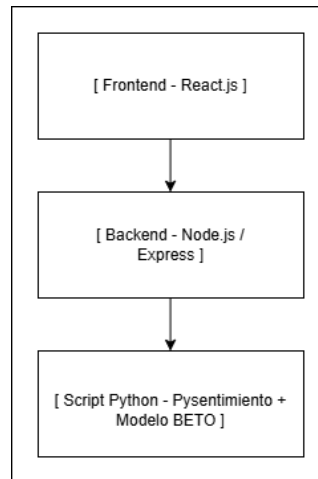


Figura 8: Diagrama de componentes

- Comunicación interna con ejecución de script vía `child_process`
- Arquitectura monolítica dividida por responsabilidades
- Despliegue local para pruebas de investigación

Mapa de navegación

En la figura 9 se presenta de forma gráfica la visualización simplificada de la navegación dentro de la aplicación, mostrando en forma secuencial, como el usuario sería capaz de explorar, visualizar e interactuar con las diferentes secciones de la aplicación, además de los diferentes componentes que forman parte de cada sección.

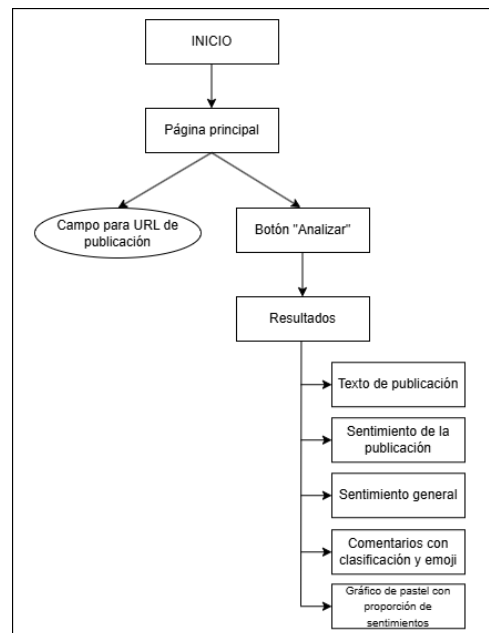


Figura 9: Mapa de navegación

Fase 3: Implementación

La aplicación web fue desarrollada en la fase de implementación, empleando React.js para la interfaz y Node.js para el servidor. Se puso en marcha, además, un modelo de inteligencia artificial con el propósito de realizar un análisis de sentimientos.

En la tabla 6, se puede visualizar el código de la página introductoria, en la que se le solicita al usuario la URL de la publicación que se desea analizar

Tabla 6: Homepage

Código
<pre> import { useNavigate } from "react-router-dom"; import { useState } from "react"; import axios from "axios"; export default function HomePage() { const [url, setUrl] = useState(""); const navigate = useNavigate(); const handleAnalyze = async () => { try { const response = await axios.post("http://localhost:4000/api/analyze", { url }); // Guarda análisis en localStorage localStorage.setItem("analysisResult", JSON.stringify(response.data)); navigate("/dashboard", { state: { analysis: response.data } }); } catch (error) { console.error("Error al analizar publicación:", error); alert("Ocurrió un error al analizar la publicación."); } }; return (<div className="min-h-screen flex items-center justify-center bg-gradient-to-br from-pink-500 to-yellow-500 p-4"> <div className="bg-white p-8 rounded-xl shadow-xl max-w-xl w-full"> <h1 className="text-2xl font-bold text-center mb-4 text-gray-800"> Análisis de Sentimientos en Instagram </h1> <input type="url" placeholder="https://www.instagram.com/p/abc123" value={url} onChange={(e) => setUrl(e.target.value)} className="w-full px-4 py-3 border border-gray-300 rounded-lg mb-4" /> <button onClick={handleAnalyze} className="w-full bg-gradient-to-r from-purple-600 to-pink-600 text-white py-3 rounded-lg hover:opacity-90 transition" > Analizar publicación </button> </div> </div>); } </pre>

La tabla 7 contiene el código correspondiente a la página que cumple la función de dashboard para la muestra de los resultados del análisis de sentimiento

Tabla 7: Dashboard

Código

```

import { useLocation } from "react-router-dom";
import SentimentCard from "../Components/SentimentCard";
import CommentList from "../Components/CommentList";
import SentimentPieChart from "../Components/SentimentPieChart";

function getDominantSentiment(comments) {
  const counts = { Positivo: 0, Neutro: 0, Negativo: 0 };
  comments.forEach(({ sentiment }) => {
    if (counts[sentiment] !== undefined) {
      counts[sentiment]++;
    }
  });
  const dominant = Object.entries(counts).reduce((a, b) => (a[1] > b[1] ? a : b));
  return { sentiment: dominant[0], confidence: dominant[1] / comments.length };
}

function getEmoji(sentiment) {
  switch (sentiment) {
    case "Positivo":
      return "😊";
    case "Negativo":
      return "😡";
    case "Neutro":
      return "😐";
    default:
      return "😐";
  }
}

export default function Dashboard() {
  const { state } = useLocation();
  const analysisFromState = state?.analysis;
  const analysis = analysisFromState || JSON.parse(localStorage.getItem("analysisResult"));

  if (!analysis) return <p className="text-center mt-10">No hay datos para mostrar.</p>;

  const { sentiment: generalSentiment, confidence: generalConfidence } =
    getDominantSentiment(analysis.comments);

  const sentimentCounts = analysis.comments.reduce(
    (acc, c) => {
      acc[c.sentiment] = (acc[c.sentiment] || 0) + 1;
      return acc;
    },
    { Positivo: 0, Neutro: 0, Negativo: 0 }
  );

  return (
    <div className="max-w-5xl mx-auto mt-10 p-6 bg-white rounded-xl shadow-md">
      <h2 className="text-2xl font-bold mb-4">Resultados del análisis</h2>
      <p className="mb-1 text-gray-600 break-all">
        Publicación analizada: <span className="text-blue-600">{analysis.post}</span>
      </p>
      <p className="mb-6 text-gray-600">
        Esta publicación se percibe como: <span className="font-bold text-green-600">{getEmoji(analysis.postSentiment)} {analysis.postSentiment}</span>
      </p>

      <div className="grid grid-cols-1 md:grid-cols-2 gap-6">
        <SentimentCard sentiment={generalSentiment} confidence={generalConfidence} />
        <div className="bg-white rounded-xl p-6 shadow-lg">
          <h3 className="text-lg font-semibold mb-4 text-center">
            Distribución de Sentimientos
          </h3>
          <SentimentPieChart sentimentCounts={sentimentCounts} />
        </div>
      </div>
    </div>
  );
}

```

```

<div className="mt-10">
  <CommentList
    comments={analysis.comments.map((c) => ({
      text: c.text,
      sentiment: c.sentiment
    })))}
  />
</div>
</div>
);
}

```

En la tabla 8, se tiene el código correspondiente al análisis de sentimiento en el backend.

Tabla 8: Proceso de análisis de sentimiento

Código
<pre> const { exec } = require('child_process'); async function analyzeSentiment(post, comments) { // Analizar texto del post const postResult = await analyzeText(post); // Analizar comentarios const analyzedComments = await Promise.all(comments.map(analyzeText)); return { post, postSentiment: mapLabel(postResult.label), postConfidence: postResult.confidence, postAnalysis: [postResult], comments: comments.map((text, i) => ({ text, sentiment: mapLabel(analyzedComments[i].label), confidence: analyzedComments[i].confidence, analysis: [analyzedComments[i]] }))) }; } // Función para llamar a analyze.py function analyzeText(text) { return new Promise((resolve, reject) => { exec(`python analyze_sentiment.py "\${text.replace(/"/g, "\\\"")}"`, { cwd: __dirname + '/../.' }, (err, stdout) => { if (err) return reject(err); try { const data = JSON.parse(stdout); resolve(data); } catch (e) { reject(new Error("Error al parsear salida de Python")); } }); }); } // Mapeo de etiquetas a español function mapLabel(label) { const map = { POS: 'Positivo', NEU: 'Neutro', NEG: 'Negativo' }; </pre>

```

return map[label] || 'Neutro';
}

module.exports = analyzeSentiment;

```

En la figura 10, se observa el diseño del homepage, la cual es la primera página con la que interactúa el usuario

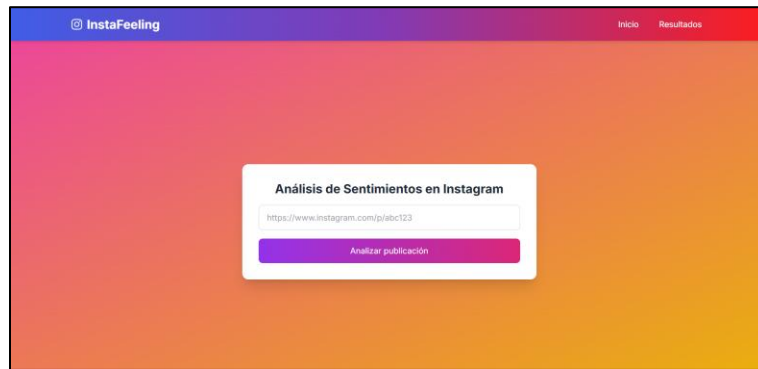


Figura 10: Homepage

La figura 11 muestra la página de dashboard donde se puede visualizar el resultado del análisis de sentimiento

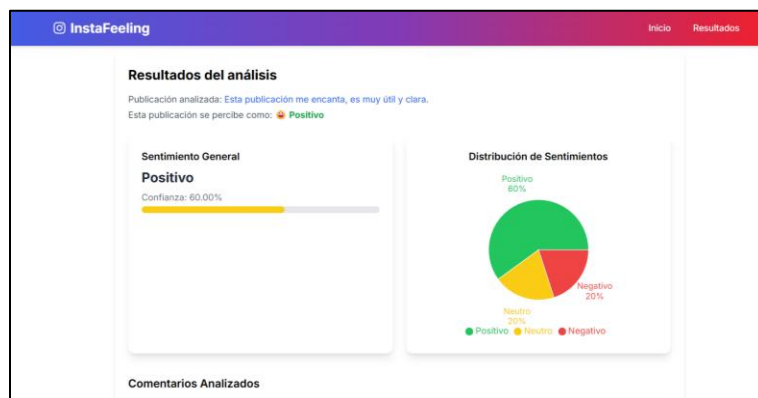


Figura 11: Dashboard

Fase 4: Pruebas

a) Planificación de pruebas

La fase de pruebas de la aplicación web para el análisis de sentimientos en publicaciones y comentarios de Instagram utilizando técnicas de IA tiene como finalidad validar el cumplimiento de los objetivos técnicos, funcionales y de precisión previamente establecidos, permitiendo verificar y mejorar la aplicación mediante ciclos sucesivos basándose en los resultados obtenidos.

Pruebas funcionales: verificación de la realización de las tareas y el flujo completo de la aplicación, lo que abarca:

- Ingreso de la URL de la publicación de Instagram en la interfaz web.

- Extracción automática de los comentarios.
- Envío del contenido textual al módulo de análisis.
- Ejecución del modelo IA para clasificar los sentimientos.
- Presentación gráfica de los resultados al usuario.

Rendimiento del modelo de IA: Se estudiaron las métricas de efectividad, tales como la precisión, el recall y el F1-score, del modelo de análisis de emociones pysentimiento/robertuito-sentiment-analysis, que se empleó para analizar y clasificar la publicación y sus comentarios obtenidos de Instagram.

Procedimiento

- Se eligieron meticulosamente las publicaciones de acceso abierto que incluían los comentarios pertinentes.
- Se realizó la puesta en marcha del sistema completo con el propósito de clasificar y extraer esos comentarios automáticamente.
- Cada comentario fue también etiquetado manualmente por el investigador para comparar resultados.
- A través de la comparación, se generó una matriz de confusión.
- Se determinaron los índices de rendimiento empleando métodos de evaluación convencionales.

Criterios de aceptación

- El modelo debía obtener, al menos en dos de las tres categorías emocionales, un mínimo del 80% de F1-score.
- La aplicación debía gestionar cada publicación sin cometer fallos de ejecución.
- El sistema tenía que sostener un acuerdo de más del 80% entre la valoración humana y la categorización automática.

b) Ejecución de las pruebas

Durante esta fase se realizaron pruebas para evaluar el comportamiento de cada componente de la aplicación tanto funcionales como de desempeño del modelo para el análisis de sentimientos, enfocándose en métricas como la precisión, recall y F1-score, además de los niveles correspondientes al Frontend, Backend y la extracción de los datos.

• Pruebas de funcionamiento

A continuación, en la tabla 9, se evidencia los resultados de la evaluación del funcionamiento general del sistema.

Tabla 9: Pruebas de funcionamiento

Caso	Descripción	Resultado esperado	Resultado obtenido	Estado
CP-01	Ingresar URL válida de una publicación de Instagram	Se debe extraer el texto y los comentarios	Datos obtenidos correctamente	✓

CP-02	Ingresar URL inválida	Mostrar mensaje de error y no ejecutar análisis	Mensaje de error mostrado	✓
CP-03	Click en botón “Analizar Sentimiento”	Ejecuta análisis con modelo RoBERTuito	Resultado del análisis mostrado en pantalla	✓
CP-04	Publicación con comentarios	Analiza el texto principal y los comentarios	Resultado basado en el texto de la publicación y de los comentarios	✓
CP-05	Publicación sin comentarios	Solo se analiza el texto principal	Resultado basado en el texto de la publicación	✓

• Pruebas de integración

Se validó que el flujo completo de la aplicación funcione sin errores:

- Login y extracción de datos con Puppeteer.
- Desarrollo de un guion en Python enfocado en el backend para realizar análisis de carácter emocional.
- Los datos procesados se representan a través de una interfaz de usuario desarrollada en React.

```

Server escuchando en http://localhost:4000/api/analyze
Abriendo navegador con Puppeteer...
Iniciando sesión en Instagram...
Login completado.
Navegando a la publicación: https://www.instagram.com/p/DKheGm20I4y/
texto extraído: {
  captionRaw: '¡Hambre de goles! La selección está on fire 🏆🔥 y no hay nada más ecuatoriano que cantar SÍ SE PUEDE con
  'Obviamente si ganamos 🏆🔥🔥🔥🔥🔥🔥',
  'Claro que ganamos Ecuador si se puede 🏆🔥',
  'Claro q ganamos esa victoria se queda aquí en Ecuador 🏆',
  'Si se puede con Dios y nuestros muchachos vamos a salir victorioso 🏆',
  'Hoy ganamos con fe🏆🔥',
  'Vamos a ganar Ecuador el mejor 🏆',
  'Ecuador 2 vs 1 Brasil',
  'Ecuador 2 Brasil 0',
  'Ganamos',
  'Vamos a darle',
  'Vamos tricolor si se puede.. si se puede si se puede...🏆🔥🔥🔥🔥🔥 ECECECECECA ponerle ñeque y corazón chicos lindos 🏆',
  '🏆🔥🔥🔥',
  'Ganamos por que ganamos con fe',
  'Si se puede 🏆',
  'gana la Tri 🏆🔥'
}

```

Figura 12: Pruebas de integración

• Pruebas de desempeño del modelo

Para la realización de la evaluación del rendimiento del modelo, tal como se detalló en la muestra de la población en este trabajo de investigación, se tomaron 385 muestras de comentarios de usuarios regulares, influenciadores y marcas, los cuales fueron etiquetados manualmente para realizar la comparación con la etiquetas del modelo y se calcularon las métricas precisión, recall y F1-Score.

En la tabla 10 se observa los resultados obtenidos de la evaluación del rendimiento del modelo.

Tabla 10: Pruebas de desempeño del modelo

Clase	Precisión	Recall	F1-Score
-------	-----------	--------	----------

Negativa	0.92	1.00	0.96
Neutral	1.00	0.61	0.75
Positiva	0.77	1.00	0.87
Promedio macro	0.90	0.87	0.86

En la figura 13, se observa la matriz de confusión producto de las pruebas de desempeño del modelo.

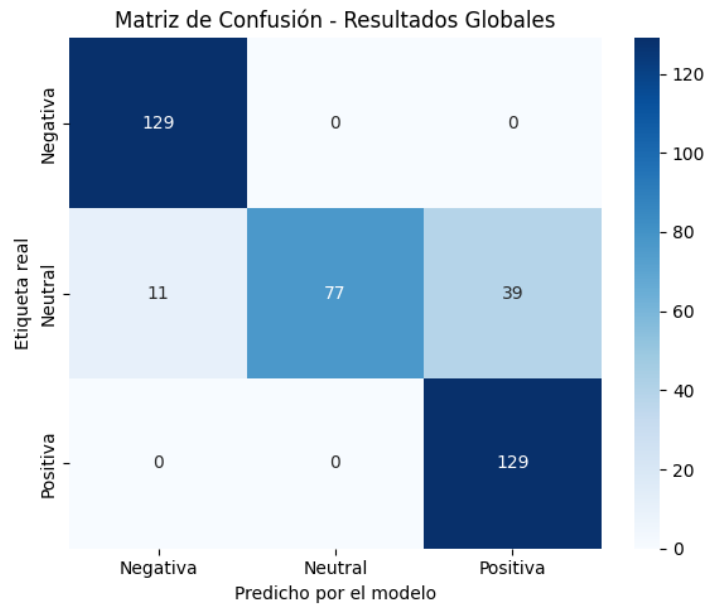


Figura 13: Matriz de confusión

CAPÍTULO IV. RESULTADOS Y DISCUSIÓN

4.1 Resultados

4.1.1 Resultado del Objetivo Específico de Investigación

Las métricas de evaluación más utilizadas en el análisis de sentimientos y los modelos basados en Transformer, como la precisión, el recall y el F1-score, han sido cuestionadas debido a la falta de un estándar globalmente aceptado para clasificar sus valores en rangos como "bajos", "aceptables" o "altos". Investigaciones recientes en profundidad han revelado nuevas tendencias y características en el rendimiento de los modelos.

Como señalaron Mosbach et al. (2021), los modelos basados en BERT y sus variantes alcanzan valores de F1-score superiores al 80 % en tareas de clasificación de sentimientos, dichas puntuaciones reflejan que, valores por debajo de ese umbral representan desequilibrio o insuficiencia de datos. Tal como lo demostró la investigación de Tay et al. (2022) sobre arquitecturas Transformer eficientes, muestra que los modelos modernos tienden a obtener valores de precisión cercanos o superiores al 85% en tareas de PLN supervisadas, lo que permite establecer puntos de referencia prácticos para futuras evaluaciones del rendimiento de los modelos.

Al examinar a fondo las pautas de estos documentos, no solo somos capaces de hacer clasificaciones descriptivas razonables, sino también de reducir el efecto del funcionamiento del modelo en las categorías cualitativas (como bajo, aceptable, alto, excelente, etc.). A partir de estas tendencias en la literatura, se pueden definir rangos de interpretación que facilitan la comprensión del rendimiento de un modelo respecto a categorías cualitativas. Estos rangos no son un estándar formal, sino una adaptación fundamentada en pruebas empíricas que han sido destacadas en la literatura reciente, lo que justifica su uso como un método interpretativo en este estudio.

A continuación, en la Tabla 11 se detallan los rangos de desempeño del modelo según la revisión bibliográfica.

Tabla 11: Rangos de desempeño

Rango	Valor numérico	Interpretación común en la literatura
Muy alto	≥ 0.90	Un rendimiento excelente, un comportamiento estable y unos pocos errores.
Alto	0.80 – 0.89	Un enfoque claro que revela una combinación acertada entre precisión y sensibilidad
Aceptable	0.70 – 0.79	En líneas generales, un resultado que es aceptable y tiene la capacidad de ser aplicado en una diversidad de usos.
Bajo	0.60 – 0.69	Un modelo que necesita ser ajustado, ya que es inestable para el ambiente real.
Muy bajo	< 0.60	Un desempeño insatisfactorio no es adecuado para las labores reales.

De acuerdo con los rangos establecidos en la Tabla 11, se compararon diferentes algoritmos preentrenados para el análisis de sentimientos en redes sociales como Beto, Naive Bayes, Random Forest, RoBERTa, entre otros, siendo pysentimiento/robertuito-sentiment-analysis el elegido para esta aplicación, debido a su optimización para lenguaje informal de redes

sociales y la clasificación por etiquetas. Los valores teóricos reportados en la literatura (Tabla 1) muestran que los modelos basados en Transformers, como BETO o BERT, alcanzan F1-scores cercanos al 0.88, superando a los algoritmos clásicos como Naive Bayes o SVM, que no superan el 0.81. En el presente estudio, el modelo RoBERTuito obtuvo un F1-score promedio de 0.86 (Tabla 10), valor consistente con los resultados teóricos, lo que confirma que este tipo de arquitecturas ofrece un alto desempeño en tareas de análisis de sentimientos.

A continuación, en la Tabla 12 se muestra una comparación de diferentes modelos preentrenados de análisis de sentimientos.

Tabla 12: Comparación de modelos de análisis de sentimientos

Modelo	Idioma / Entrenamiento	Tipo de etiquetado de sentimientos	Área de aplicación principal	Ventajas	Limitaciones
RoBERTuito (pysentimiento)	Español nativo	Tricategórico	Redes sociales	Con una alta precisión en textos cortos y coloquiales; resistente a la jerga de redes sociales, los emojis y las abreviaturas.	Menos indicado para escritos largos o formales
BETO	Español general	Tricategórico	PLN de Textos formales	Rendimiento global sobresaliente; base firme para diversas actividades.	Si no se adapta de forma concreta, el desempeño en el lenguaje informal de las redes sociales es más bajo.
mBERT	Multilingüe	Sin especificar	Aplicaciones multilingües, textos formales	Flexible, opera con varios idiomas sin requerir una nueva formación.	No está optimizado para las redes sociales y tiene un rendimiento inferior en español.
XLNet-RoBERTa	Multilingüe optimizado	Sin especificar	PLN de Textos largos	Es potente, puesto que presenta un alto rendimiento total en el procesamiento de textos.	Más costoso en términos computacionales; no se especializa en redes sociales.
DistilBETO	Español	Tricategórico	Aplicaciones móviles	Ligero y ágil; conserva un rendimiento ideal.	Menos precisión que los modelos integrales; no se enfoca en las redes sociales.

De acuerdo con lo observado en la Tabla 12, se sustenta la elección del modelo pysentimiento/robertuito-sentiment-analysis mediante una comparación que se basó en factores como el idioma, la clase de etiquetado de emociones y el campo de aplicación. A diferencia de modelos más amplios como BETO o multilingües como mBERT y XLNet-RoBERTa, RoBERTuito fue adiestrado específicamente con lenguaje coloquial español proveniente de redes sociales. Por lo tanto, es apto para el estudio de contenido y opiniones en redes sociales como Instagram, las cuales son famosas por utilizar acrónimos, emojis y un lenguaje informal.

4.1.2 Resultado del Objetivo Específico de Implementación

- **Pruebas de funcionamiento**

Durante la fase de pruebas de funcionamiento del sistema se verificó que la aplicación ejecutara de forma correcta todas las funciones integradas, las cuales incluyen el ingreso de una URL válida de Instagram, la extracción del texto de la publicación y los comentarios, el análisis de sentimiento, la clasificación de estos últimos y la presentación de los resultados.

Estas pruebas mostraron que la aplicación cumplió con los requerimientos especificados en el análisis inicial. En la Tabla 9 correspondiente a las pruebas de funcionamiento se evidencia que todos los escenarios planteados fueron exitosos. Demostrando así, que, la lógica de la aplicación y la interfaz se comportan de manera robusta ante distintos escenarios posibles.

- **Pruebas de integración**

En la fase de pruebas de integración se evaluó el flujo del sistema entre el frontend, backend y el modelo de análisis de sentimientos.

- Puppeteer con Stealth Plugin permitió obtener un acceso mediante login a las publicaciones públicas de Instagram y la extracción de datos sin restricciones.
- El backend en Node.js realizó correctamente la transferencia de datos al script de análisis de sentimientos.
- El script de análisis de sentimientos clasificó exitosamente el texto de la publicación y comentarios.
- El frontend en React.js presentó correctamente los resultados del análisis de la publicación y los comentarios.

Como se puede observar en la figura 12, en la que se muestra que el flujo del sistema se ejecutó sin errores durante las pruebas, validando así la integración entre módulos.

4.1.3 Resultado del Objetivo Específico de Evaluación

Para la evaluación del desempeño del sistema se empleó la misma arquitectura utilizada para el diseño del prototipo. Como se muestra en la Figura 7, el esquema detalla las herramientas empleadas, como la selección de React.js, Node.js y Puppeteer. Esta arquitectura constituye la base del entorno experimental sobre el cual se evaluaron las métricas de precisión, recall y F1-score.

Se efectuó un estudio con el fin de evaluar lo efectivo que es el sistema pysentimiento/robertuito-sentiment-analysis para detectar emociones. Un total de 385 comentarios y publicaciones de Instagram fueron clasificados manualmente como positivos, negativos o neutrales, dando como resultado que el modelo tuviese un desempeño sobresaliente, especialmente al distinguir entre textos positivos y negativos, con una puntuación media de 0.86 en el F1-score.

Además, como se evidencia en la figura 13, la matriz de confusión muestra una clara tendencia del modelo a confundir textos que se perciben como neutrales clasificándolos

como positivos, situación que puede resultar común al emplear textos ambiguos o coloquiales.

4.2 Discusión

4.2.1 Funcionamiento del sistema

Los resultados que se obtuvieron en las pruebas de funcionamiento del sistema evidencian la estabilidad, intuitividad y capacidad con la que cuenta la aplicación para la correcta ejecución de todas y cada una de sus funcionalidades, respaldando la eficacia de la arquitectura implementada, sin embargo en cuanto a la velocidad de procesamiento por publicación, los resultados no fueron los esperados, pudiendo deberse a la utilización de Puppeteer para la obtención de información por el consumo de recursos y el tiempo de cómputo necesario para la obtención de la publicación que se desea analizar.

Según Rosero Gómez (2022), la eficiencia de las herramientas de captura depende en gran medida del desempeño de los sistemas que ejecutan trabajos de minería de datos y extracción de información, siendo los métodos que emplean automatización a través de navegadores virtuales los que cuentan con una mayor estabilidad con la consecuencia de un notable incremento en el tiempo de ejecución. En contraposición, investigaciones como la de Muñoz Cano (2023), reportan menores tiempos de procesamiento de información en una aplicación de análisis de sentimientos en Twitter, al emplear directamente la API de la red social, demostrando así que el método de obtención de la información impacta de manera directa con la velocidad de funcionamiento del sistema.

4.2.2 Integración del sistema

La exitosa integración entre los sistemas Puppeteer, Node.js, React.js y el modelo de IA, valida la elección de estas tecnologías para el desarrollo de la aplicación, ejecutándose correctamente y sin errores o pérdidas de datos. Concordando con la propuesta de Cardona Amaya (s.f.), quien evidenció la efectividad del uso en conjunto de React y Node.js para la creación de aplicaciones web con alta interactividad y rendimiento estable en tiempo de ejecución.

Si bien la utilización de Puppeteer en este trabajo de investigación se adapta de gran manera con las demás herramientas implementadas, es quizás el apartado que, para proyectos similares, podrían ser intercambiado por una herramienta más ligera como Playwright o Selenium 4 para la obtención de información o en su defecto la implementación de la API oficial.

4.2.3 Desempeño del modelo

El modelo RoBERTuito, empleado para el análisis de sentimientos en este proyecto, obtuvo resultados superiores al 85% en métricas claves, valor con el que supera los criterios de aceptación planteados. Tanto la clase positiva como la negativa obtuvieron valores altos de precisión, pero la clase neutral presento valores de recall inferiores, esto puede deberse a diferentes factores que afectan a la interpretación del texto por parte del modelo.

Por el contrario de lo expuesto por Alemán Viteri (2021), quien aplicando herramientas tradicionales como VADER y TextBlob, obtuvo valores de precisión que rondaban el 75%, demostrando así que los modelos Transformer empleados en el presente estudio ofrecen una mayor comprensión contextual y semántica del lenguaje natural, comparable con el rendimiento obtenido por Lovera y Cardinale (2023), con valores de F1-score que oscilaban entre 0.84 y 0.87 en análisis de sentimientos en Twitter.

Por ende, se puede concluir que la aplicación de métodos avanzados de inteligencia artificial tiene un impacto importante en la eficacia de esta aplicación web, debido a su habilidad para llevar a cabo análisis exactos, coherentes y contextualizados, pese al alto costo computacional.

CAPÍTULO V. CONCLUSIONES Y RECOMENDACIONES

5.1 Conclusiones

- Los modelos de procesamiento de lenguaje natural (PLN), particularmente aquellos que se fundamentan en arquitecturas tipo Transformer, como RoBERTuito, ofrecen notables beneficios en comparación con los modelos convencionales, en particular en labores de análisis de emociones en español. Durante este estudio, se estableció que estas técnicas facilitan una mejor comprensión del contexto lingüístico, lo que resulta crucial para interpretar correctamente el contenido emocional en las redes sociales.
- Se emplearon React y otras tecnologías para crear una aplicación web que posibilita el análisis de los sentimientos de las publicaciones y comentarios hechos en Instagram. Node para la interfaz de usuario, JavaScript. JavaScript servirá para la parte del backend y Python incorporará RoBERTuito como herramienta para el análisis de sentimientos. Esta configuración hizo que el proceso se automatizara completamente, lo que permitió que Puppeteer reuniera textos, los analizara y los presentara.
- El modelo obtuvo un promedio de 0.86 en F1-Score, con un porcentaje general de precisión del 90% y un recall medio del 87%. Esto pone de manifiesto un rendimiento alto al identificar emociones, tanto las positivas como las negativas y las neutras. Las evaluaciones de las emociones positivas y negativas arrojaron resultados favorables, mientras que la emoción neutral presentó una tasa de identificación menos efectiva, debido a la confusión común en estos comentarios. Además, el sistema gestionó todas las entradas analizadas de forma impecable, cumpliendo así con los requisitos fundamentales necesarios para la evaluación.

5.2 Recomendaciones

- Explorar y comparar otros modelos de lenguaje basados en Transformers, utilizando conjuntos de datos más amplios y enfocados en redes sociales, con el fin de mejorar su comprensión del contexto y aumentar su precisión, incluyendo versiones multilingües o adaptadas al dominio específico de redes sociales, con el fin de determinar si existe un modelo que supere el desempeño de RoBERTuito en el análisis de textos informales en español.
- Optimizar los módulos de la aplicación, en especial el modulo encargado de la obtención de datos desde Instagram y añadir funcionalidades orientadas a la generación, guarda y visualización de informes, además de filtros de búsqueda y análisis de multiples publicaciones en lote con el propósito de optimizar su funcionalidad y uso en contextos empresariales o profesionales.
- Implementar una etapa de procesamiento avanzado de texto que complemente al análisis de sentimientos, permitiendo la identificación de patrones que incluya lenguaje informal, emojis y expresiones ambiguas con el fin de reducir errores de clasificación.

BIBLIOGRAFÍA

- Alastruey, C. F. (2021). State of the Art in Artificial Intelligence and Learning Machines. (*Tesis de pregrado*). Universidad Pública de Navarra. https://doi.org/https://doi.org/10.24197/st.Extra_2.2021.182-195
- Albuja Sánchez, B., & Guadalupe Almeida, J. L. (2022). Áreas de estudio y aplicación de inteligencia artificial en las universidades mejor puntuadas del Ecuador. *Revista Científica y Tecnológica UPSE*, 58-74. <https://doi.org/https://doi.org/10.26423/rctu.v9i2.705>
- Alemán Viteri, S. B. (2021). Análisis de sentimientos para Twitter con Vader y TextBlob. *ODIGOS*, 9-25. <https://doi.org/https://doi.org/10.35290/ro.v2n3.2021.494>
- Beltrán, N. C., & Rodríguez, E. C. (2021). Procesamiento del lenguaje natural (PLN) -GPT-3, y su aplicación en la Ingeniería de Software. *TIA*, 18-37. <https://revistas.udistrital.edu.co/index.php/tia/article/view/17323>
- Brown, T., Mann, B., Ryder, N., Subbiah, M., Kaplan, J. D., Dhariwal, P., . . . Ramesh, A. (2020). Language models are few-shot learners. *Advances in neural information processing systems. NeurIPS Proceedings*. https://proceedings.neurips.cc/paper_files/paper/2020/file/1457c0d6bfc4967418bfb8ac142f64a-Paper.pdf
- Calle García, A. J., Quimis Vera, M. C., Piguave Vargas, M. T., & Zambrano Luzardo, J. S. (2023). LA INTELIGENCIA ARTIFICIAL COMO HERRAMIENTA EN LA SEGMENTACIÓN DE MERCADO. *Ciencia y Desarrollo*, 193-202. <http://revistas.uap.edu.pe/ojs/index.php/CYD/index>
- Campos Sánchez, J. J., González Gutiérrez, F., & Castillo Velásquez, F. A. (2024). Revisión Sistemática de Técnicas de Tokenización para la Clasificación de información en Inteligencia Artificial. *Memorias del Congreso Estudiantil de Inteligencia Artificial aplicada a la ingeniería y tecnología*, 24-27. <https://virtual.cuautitlan.unam.mx/intar/memoriasceiaait/ano-6-tomo-6/>
- Cardona Amaya, S. (n.d.). DESARROLLO APLICATIVO WEB MEDIANTE EL USO DE REACT Y NODEJS. (*Informe final de prácticas*). Tecnológico de Antioquia - Institución Universitaria, Medellín.
- Cedeno Moreno, D., & Vargas Lombardo, M. (2020). Aprendizaje automático aplicado al análisis de sentimientos. *I+D Tecnológico*.
- Celi Parraga, R. J., Varela Tapia, E. A., Acosta Guzmán, I. L., & Montaña Pulzara, N. R. (2021). Natural language processing techniques in textual conversational artificial intelligence. *Alfa*, 40-52. <https://doi.org/https://doi.org/10.33262/ap.v3i4.106>

- García Riquero, A. G. (2023). Estudio de un aplicativo web inteligente basado en lenguaje natural para definir temas de investigación óptimos en la Universidad Técnica de Babahoyo. (*Tesis de pregrado*). Universidad Técnica de Babahoyo, Babahoyo, Ecuador. <http://dspace.utb.edu.ec/handle/49000/14180>
- Guzmán Landa, J. J., Hernández Hernández, J. C., Hoyos Rivera, G. d., & Mezura-Montes, E. (2023). Selección de características de representaciones de texto de BETO usando un algoritmo genético. *Computing Science*, 191-202. https://www.rcs.cic.ipn.mx/2023_152_7/Seleccion%20de%20caracteristicas%20de%20representaciones%20de%20texto%20de%20BETO%20usando%20un%20algoritmo%20genetico.pdf
- Intriago Camacho, A. J. (2023). Desarrollo de una interfaz web de una herramienta de análisis de sentimientos para Tweets (con Twitter). (*Tesis de pregrado*). Universidad Politécnica de Madrid, Madrid. <https://oa.upm.es/75388/>
- José, C., Gabriel, C., Rodrigo, F., Jou-Hui, H., Hojin, K., & Jorge, P. (2023). Spanish Pre-trained BERT Model and Evaluation Data. *arXiv*. <https://doi.org/2308.02976>
- Kian Long Tan, C. P., & Kian Ming, L. (2023). A survey of sentiment analysis: Approaches, datasets, and future research. *Applied Sciences*. <https://doi.org/https://www.mdpi.com/2076-3417/13/7/4550>
- Lovera, F. A., & Cardinale, Y. (2023). Análisis de sentimientos en Twitter: Un estudio comparativo. *Revista Científica de Sistemas e Informática*. <https://doi.org/https://doi.org/10.51252/rcsi.v3i1.418>
- Lozano González, J. E. (2025). Revisión sistemática sobre el análisis de sentimientos en interacciones por chat en videojuegos. (*Monografía*). Universidad Nacional Abierta y a Distancia UNAD, Medellín. <https://repository.unad.edu.co/handle/10596/67163>
- Martín Climenta, P., & Moreno García, J. M. (2022). Aplicación de la inteligencia artificial en el laboratorio. *Medicina Reproductiva y Embriología Clínica*, 1-14. <https://doi.org/https://doi.org/10.1016/j.medre.2022.100119>
- Migliorata, E., & Dahl, J. R. (2020). Diseño e Implementación de una aplicación web orientada a carpooling aplicando prácticas y tecnologías innovadoras maximizando la eficiencia y calidad del producto. (*Tesis de pregrado*). Universidad Nacional del Centro de la Provincia de Buenos Aires, Buenos Aires. <https://www.ridaa.unicen.edu.ar/handle/123456789/2359>
- Mosbach, M., Andriushchenko, M., & Klakow, D. (2021). On the Stability of Fine-tuning BERT: Misconceptions, Explanations, and Strong Baselines. *arXiv*. <https://doi.org/https://doi.org/10.48550/arXiv.2006.04884>

- Muñoz Cano, S. (2023). Desarrollo de una aplicación web para el análisis de sentimientos en publicaciones en Twitter. (*Trabajo de pregrado*). Universidad Miguel Hernández de Elche.
- Palomino Bravo, M. (2023). Los Grandes Modelos del Lenguaje basados en Transformers: revisión y aplicación práctica con ChatGPT. (*Trabajo de pregrado*). Universidad Pontificia Comillas. <https://repositorio.comillas.edu/xmlui/bitstream/handle/11531/69691/TFG-Palomino%20Bravo%2c%20Marina.pdf?sequence=2&isAllowed=y>
- Patricio Guisado, M. Á., & Berlanga de Jesús, A. (2020). Procesamiento del lenguaje natural con BERT: Análisis de sentimientos en tuits. (*Trabajo Fin de Grado*). Universidad Carlos III de Madrid. <https://e-archivo.uc3m.es/rest/api/core/bitstreams/a10e2295-b239-4305-aad1-1570259607bf/content>
- Pérez, J. M., Rajngewerc, M., Giudici, J. C., Furman, D., Luque, F., Alemany, L. A., & Martinez, M. V. (2021, Julio 13). A Python Toolkit for Opinion Mining and Social NLP tasks. (*Tesis de pregrado*). Universidad de Buenos Aires, Buenos Aires, Argentina. arXiv: <https://arxiv.org/abs/2106.09462>
- Plaza del Arco, F. (2024). La calidad de los datos es fundamental para detectar los sesgos de la IA. *EL PAIS*. <https://elpais.com/tecnologia/2024-08-22/flor-plaza-del-arco-informatica-la-calidad-de-los-datos-es-fundamental-para-detectar-los-sesgos-de-la-ia.html>
- Porta Zamorano, J., & Sancho Sánchez, J. L. (2021). Procesamiento de lenguaje natural aplicado a datos masivos generados en medios sociales. *Revista Española de Lingüística*, 111-124.
- Rosenbrock, G., Trossero, S., & Pascal, A. (2021). Técnicas de análisis de sentimientos aplicadas a la valoración de opiniones en el lenguaje español. *Sedici*, 291-300. https://sedici.unlp.edu.ar/bitstream/handle/10915/130344/Documento_completo.pdf?sequence=1
- Rosero Gómez, J. D. (2022). Desarrollo de un aplicativo web para monitorear efectos psicológicos de una pandemia usando técnicas de minería de datos e información de noticias y tweets. (*Tesis de pregrado*). Escuela Politécnica Nacional, Quito, Ecuador. <http://bibdigital.epn.edu.ec/handle/15000/22892>
- Salgado Reyes, N., & Trujillo Moreno, G. E. (2024). Análisis de sentimientos en datos de redes sociales: aplicación de técnicas de procesamiento de lenguaje natural y machine learning para analizar opiniones y sentimientos en datos de redes sociales en el contexto de sistemas de información. *Dominio de las Ciencias*, 5.
- Sánchez DelaCruz, E., Herrera Contreras, A. A., & Meza, I. (2020). Modelo para Análisis de Sentimiento Utilizando Aprendizaje Automático. (*Tesis para obtener el grado de*

Maestro en Sistemas Computacionales). Instituto Tecnológico Superior de Misantla.
<https://www.researchgate.net/publication/346521755>

Tay, Y., Dehghani, M., Bahri, D., & Metzler, D. (2022). Efficient Transformers: A Survey.
arXiv. <https://doi.org/https://doi.org/10.48550/arXiv.2009.06732>

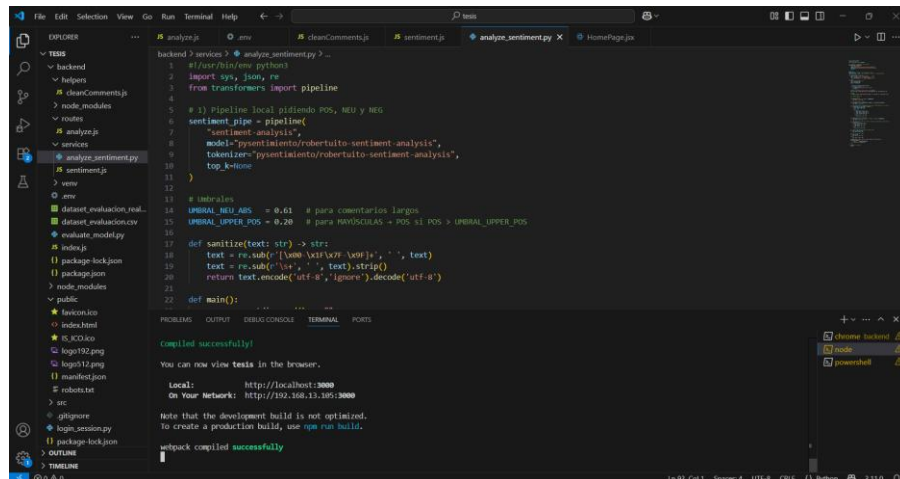
Vakaruk, S. (2023). Contribuciones a la aplicación de Machine Learning en escenarios de tiempo real. (*Tesis doctoral*). ESCUELA TÉCNICA SUPERIOR DE INGENIERÍA DE SISTEMAS INFORMÁTICOS, Madrid.
https://oa.upm.es/76518/1/STANISLAV_VAKARUK.pdf

Valderrama Santiago, P. (2021). MLOPS PARA EL DESARROLLO Y PUESTA EN PRODUCCIÓN DE MODELOS DE MACHINE LEARNING. (*Tesis de pregrado*). Universidad de Málaga, Málaga. <https://hdl.handle.net/10630/23550>

Walaa, M., Ahmed, H., & Hoda, K. (2014). Sentiment analysis algorithms and applications: A survey. *Ain Shams Engineering Journal*.
<https://doi.org/https://doi.org/10.1016/j.asej.2014.04.011>

ANEXOS

En el Anexo 1 se muestra la ejecución en consola de la aplicación.

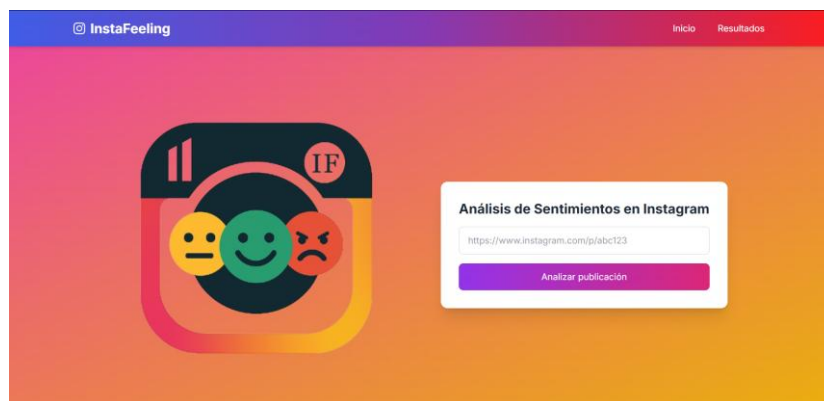


The screenshot shows a code editor with a file explorer on the left and a terminal at the bottom. The file explorer shows a project structure with folders like 'backend', 'helpers', 'node_modules', 'routes', 'services', and 'views'. The 'analyze_sentiment.py' file is selected. The terminal shows the output of the script, which includes the following code:

```
backend > services > analyze_sentiment.py > ...
1 #!/usr/bin/env python
2 import sys, json, re
3 from transformers import pipeline
4
5 # 1) Pipeline local pidiendo POS, NEU y NEG
6 sentiment_pipe = pipeline(
7     "sentiment-analysis",
8     model="pytorch/sentiment-analysis",
9     tokenizer="pytorch/sentiment-analysis",
10     top_k=None
11 )
12
13 # Interfaz
14 UNIBAL_NEU_ABS = 0.61 # para comentarios largos
15 UNIBAL_UPPER_POS = 0.28 # para MENÚSCULAS + POS si POS > UNIBAL_UPPER_POS
16
17 def sanitize(text: str) -> str:
18     text = re.sub(r'[\x00-\x08\x0b\x0c\x0e-\x1f]', '', text)
19     text = re.sub(r'[\x20-\x2f]', ' ', text).strip()
20     return text.encode('utf-8', 'ignore').decode('utf-8')
21
22 def main():
23     ...
24
25 if __name__ == '__main__':
26     main()
27
28 Compiled successfully!
29 You can now view tests in the browser.
30 Local: http://localhost:3000
31 On Your Network: http://192.168.13.105:3000
32
33 Note that the development build is not optimized.
34 To create a production build, use npm run build.
35
36 webpack compiled successfully
```

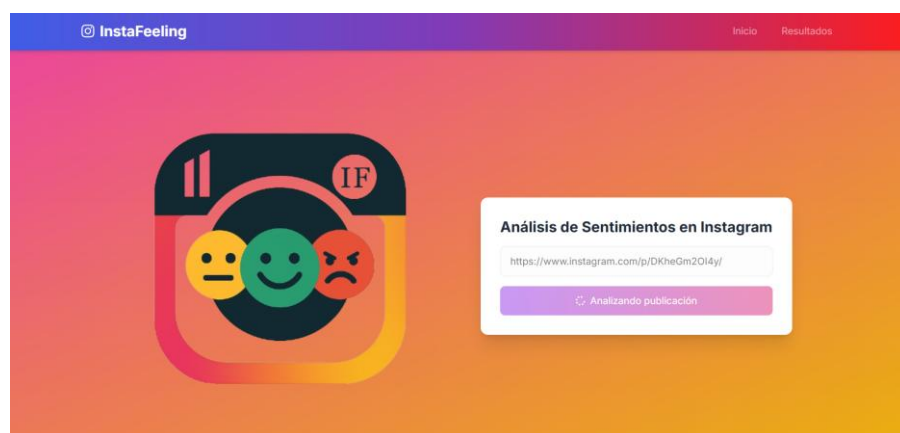
Anexo 1: Programa en ejecución

El Anexo 2 muestra la página principal de la aplicación.



Anexo 2: Pantalla principal

En el Anexo 3 se muestra el ingreso de una URL válida para la realización de análisis.



Anexo 3: Ingreso de URL

EL Anexo 4 muestra la ejecución del análisis en consola, ingreso a Instagram, navegación hasta la publicación y extracción de texto.

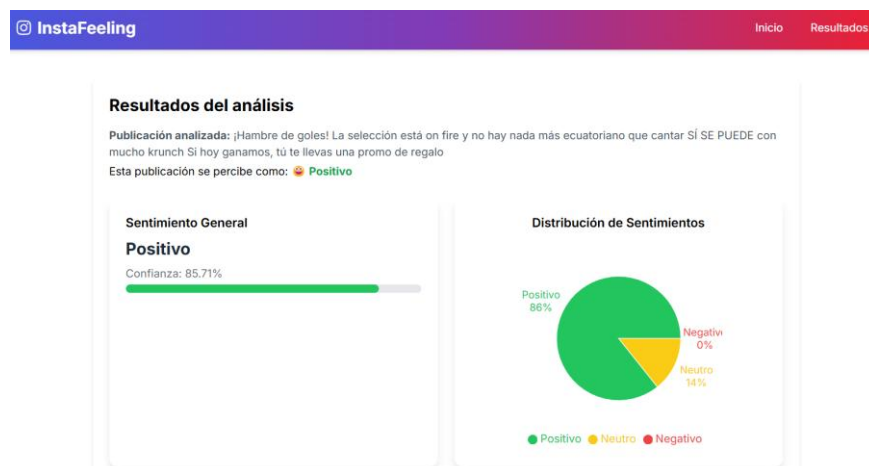
```

1 import sys, json, re
2 from transformers import pipeline
3
4 # 1) Pipeline local usando PyTorch, GPU y CPU
5 sentiment_pipe = pipeline(
6     "sentiment-analysis",
7     model="pytorch/sentiment-analysis",
8     tokenizer="pytorch/sentiment-analysis",
9     top_k=None
10 )

```

Anexo 4: Análisis de sentimiento en consola

En el Anexo 5 se puede observar el resultado del análisis, sentimiento de la publicación, sentimiento promedio de los comentarios y gráfico de pastel.




Anexo 5: Resultado de análisis

El Anexo 6 y 7 muestra el etiquetado de los comentarios según el modelo de análisis de sentimiento.



Anexo 6: Comentarios etiquetados

<div>  InstaFeeling </div> <div> <div>Inicio</div> <div>Resultados</div> </div>	
Ecuador vs Brasil	😐 Neutro
Si se puede con Dios y nuestros muchachos vamos a salir victorioso	😊 Positivo
gana la Tri	😊 Positivo
Hoy ganamos con fe	😊 Positivo
Ecuador Brasil	😐 Neutro
Vamos a darle	😊 Positivo

Anexo 7: Comentarios etiquetados