

**Prototipo de Sistema con Recomendación en Generación de Contenido
Emocional Para Redes Sociales**

Yeferson Aguiar Dominguez

**Universidad del Valle
Facultad de ingeniería
Escuela de ingeniería de sistemas y computación
Tuluá
2025**

**Prototipo de Sistema con Recomendación en Generación de Contenido
Emocional Para Redes Sociales**

Yeferson Aguiar Dominguez

Código 2067607

yeferson.aguiar@correounivalle.edu.co

Director

Joshua David Triana Madrid. Msc

joshua.triana@correounivalle.edu.co

Universidad del Valle

Facultad de ingeniería

Escuela de ingeniería de sistemas y computación

Tuluá

2025

Trabajo de grado presentado por
Yeferson Aguiar Dominguez
Como requisito parcial para la obtención del título de Ingeniero de Sistemas

Joshua David Triana Madrid
Director

Jurado

Jurado

A Dios, por brindarme la vida, la salud y la fortaleza necesarias para alcanzar este sueño. A mi familia, por su amor incondicional, su compañía constante y la confianza que siempre han depositado en mí. A mis profesores, por su orientación, dedicación y por contribuir de manera significativa a mi formación académica y personal. A todos los que hicieron partes de las pruebas tanto personas como estudiantes y egresados por ser fundamentales en el avance, desarrollo, y conclusion del trabajo. Al Ingeniero Joshua Triana, por su valiosa guía, apoyo y compromiso durante el desarrollo de este trabajo.

Tabla de contenido

1. Introducción	11
1.1. Introducción	11
1.2. Formulación del Problema	12
1.3. Descripción del problema	13
1.4. Objetivos	14
1.4.1. Objetivo General	14
1.4.2. Objetivos Específicos	14
1.5. Resultados esperados	15
1.6. Justificación	16
2. Alcance de la Propuesta	17
2.1. Entrada de datos:	17
2.2. Procesamiento:	17
2.3. Generación de contenido:	17
2.4. Dominio de la solución:	17
3. Marco Referencial	18
3.0.1. Sistemas de recomendación	18
3.0.2. Análisis de sentimientos y computación afectiva	18
3.0.3. Impacto de las emociones en la interacción en redes	18
3.0.4. Teoría de las Emociones Básicas de Paul Ekman y su Aplicación en el Análisis de Texto	18
3.0.5. Extensión de las Emociones Básicas al Análisis Semántico en Texto	19
3.0.6. Aplicaciones en Sistemas de Recomendación Al adaptar la teoría de Ekman al análisis de texto:	19
3.1. Marco Teórico	20
3.1.1. Teoría de la personalización del contenido	20
3.1.2. Teoría de la computación afectiva	20
3.1.3. Teoría de la interacción humano-computadora (HCI)	21
3.1.4. Teoría del análisis de sentimientos	21
3.1.5. Teoría de la motivación social en plataformas digitales	22
3.2. Antecedentes	22
3.2.1. Recomendación emocional en plataformas de redes sociales (2019)	22

3.2.2.	Sistema de recomendación emocional con NLP en aplicaciones de mensajería (2020)	23
3.2.3.	Plataforma de recomendación de contenido emocional con IA (2021)	23
3.2.4.	Computación afectiva para robots de compañía social mediante reconocimiento de emociones del habla de grano fino(2023)	23
3.2.5.	Sistema Multiagente Afectivo: Modelado y Simulación de los Efectos Sociales y Racionales de las Emociones (2023)	24
3.2.6.	Encuesta sobre el método de redes neuronales gráficas bajo recomendación social (2023)	24
3.2.7.	Investigación experimental de modelos de inteligencia artificial para sistemas de recomendación(2025)	25
3.3.	Términos Comunes	26
4.	Análisis de modelos y sistemas de recomendación	27
4.1.	Modelos Pros y Contras	28
4.2.	Selección Del Modelo	29
4.2.1.	Modelos emocionales	29
4.2.2.	Sistemas de recomendación	29
5.	Modelo	31
5.1.	Modelo emocional	31
5.1.1.	Pysentimiento:	31
5.2.	Modelo generativo de contenido emocional	32
5.2.1.	Comparación de Algoritmos de Filtrado Colaborativo	32
5.2.2.	Slope One	33
5.3.	Calificación de sentimiento con Pysentimiento	34
5.4.	Patrones clave identificados en publicaciones analizadas	35
5.4.1.	Usuario 1: Emocion: Joy	35
5.4.2.	Usuario 2: Emocion: Surprise	35
5.4.3.	Usuario 3: Emocion: Sadness	36
5.4.4.	Usuario 4: Emocion: Anger	36
5.4.5.	Usuario 5: Emocion: Fear	37
5.5.	Algoritmo del Modelo Emocional	38
5.6.	Justificacion del modelo	39
5.7.	Requisitos Funcionales del chatbot	40
5.8.	Diagrama UML: Casos de Uso	41

5.9. Arquitectura de diseño del chatbot	42
5.10. Interfaz del chatbot	44
6. Desarrollo Del Proyecto	47
6.1. Entorno de Desarrollo	47
6.2. Tecnologías y Frameworks a Implementar	47
6.3. Procesamiento de Texto y Sistema de Recomendación	48
6.4. Estructura de Base de datos	49
6.5. APIs Externas integradas	50
6.6. Tabla Comparativa de IA	51
6.7. API's Red Social	51
6.8. Implementacion de la aplicacion	53
6.9. Requerimientos Funcionales	53
6.10. Control De Flujo - Modelo BPMN básico	55
6.11. Consideraciones Éticas	59
7. Pruebas	60
7.1. Pruebas Funcionales y de validacion del chatbot	60
7.2. Pruebas Unitarias del algoritmo de clasificación emocional	61
7.3. Discusión de los Resultados	64
7.4. Impacto de la integración mediante pruebas de usuarios	65
7.5. Objetivo y planteamiento de las pruebas	65
7.6. Planificación de las pruebas	66
7.7. Análisis de los resultados de las pruebas con Mastodon	67
7.8. Análisis de los resultados de las pruebas con 7social	68
7.9. Aplicación y Justificación de la Prueba con Usuarios	68
7.10. Pruebas de usabilidad de nielsen	69
7.11. Análisis de los resultados	70
8. Conclusiones Comparativas	71
8.1. Conclusiones	71
8.1.1. 1. Experiencia de usuario e interacción	71
8.1.2. 2. Caracterización de patrones emocionales	71
8.1.3. 3. Diseño e implementación del chatbot emocional	71
8.1.4. 4. Integración del análisis emocional con las recomendaciones	72

8.1.5.	5. Evaluación comparativa en redes sociales	72
8.1.6.	6. Satisfacción general y proyección futura	72
8.1.7.	7.Enfoque técnico	72
9.	Trabajos Futuros	74
10.	Bibliografía	75
11.	Anexos	78

Índice de figuras

1.	Algoritmo generativo de contenido emocional	33
2.	Algoritmo del modelo emocional	38
3.	Diagrama de casos de uso	41
4.	Arquitectura de diseño del chatbot	43
5.	Interfaz Principal del chatbot	44
6.	Saludo y respuesta del chatbot	45
7.	Peticion de recomendacion	45
8.	Vista de Recomendacion	46
9.	Vista de la calificacion	46
10.	Control de flujo - Modelo BPMN basico	55
11.	Pantallas de Inicio, Registro y Feed	57
12.	Interacciones del chatbot	58
13.	Evaluación de la experiencia del usuario en la plataforma	66
14.	Efectividad del análisis emocional en la coherencia de recomendaciones	67

Índice de tablas

1.	Resultados Esperados.	15
3.	Modelos Pros y Contras	28
4.	Comparación de Algoritmos de Filtrado Colaborativo	32
5.	Patrones clave identificados en Joy	35
6.	Patrones clave identificados en Surprise	35
7.	Patrones clave identificados en Sadness	36
8.	Patrones clave identificados en Anger	36
9.	Patrones clave identificados en Fear	37
10.	Requisitos Funcionales del Chatbot	41
11.	Comparación de modelos de Inteligencia Artificial Generativa	51
12.	Comparativa entre APIs de red social.	52
13.	Pruebas del chatbot de recomendaciones.	61
14.	Test unitario emocion positiva	61
15.	Test unitario emocion negativa	62
16.	Test unitario entrada vacia	62
17.	Test unitario entrada multiple	63
18.	Test unitario entrada de simbolos	63
19.	Test unitario entrada de signos	64
20.	Test unitario entrada sin sentido	64

Resumen

El trabajo propuesto a continuación, es el desarrollo de un sistema de recomendación enfocado en la generación de contenido emocional para redes sociales basada en recopilación de texto, El objetivo es crear un sistema que sea capaz de analizar y reconocer las emociones en los textos generados por los usuarios ya que se evidencia una falencia en saber que se puede recomendar específicamente a un usuario a través de su estado emocional.

Los datos serán recolectados de manera textual de plataformas sociales, y textos cortos en donde con ayuda de un chatbot, posteriormente se generará contenido emocionalizado de acuerdo a los estados de ánimo detectados con el fin de mejorar la experiencia del usuario en las redes sociales.

Los resultados de trabajos anteriores sugieren que el sistema a implementar puede llegar a identificar con precisión las emociones como **Felicidad:** Una sensación placentera de bienestar o logro. **Tristeza:** Una reacción emocional ante una pérdida significativa. **Ira:** Una respuesta ante una injusticia, amenaza o frustración. **Miedo:** Una respuesta ante un peligro real o percibido, que prepara para la huida o la lucha. **Sorpresa:** Una reacción ante algo inesperado, que se considera la emoción más corta. **Asco:** El rechazo ante estímulos nocivos o repulsivos. **Desprecio:** el desprecio suele referirse al acto de despreciar o a la falta de respeto general por algo. En textos cortos, lo que facilitará la personalización del contenido que se recomienda al usuario. Esta propuesta se alinea con estudios basados en la importancia del contenido emocional junto con la interacción en redes sociales y la influencia que este tiene en el comportamiento de los usuarios.

Palabras Clave

Inteligencia artificial, Procesamiento del lenguaje natural, Análisis de sentimientos, Computación afectiva.

Abstract

The work proposed below is the development of a recommendation system focused on generating emotional content for social networks based on text collection. The objective is to create a system capable of analyzing and recognizing emotions in texts generated by users, as there is a clear lack of knowledge about what can be specifically recommended to a user based on their emotional state.

The data will be collected in textual form from social platforms and short texts, where, with the help of a chatbot, emotional content will subsequently be generated according to the moods detected in order to improve the user experience on social media.

The results of previous work suggest that the system to be implemented can accurately identify emotions such as: **Happiness:** A pleasant feeling of well-being or accomplishment. **Sadness:** An emotional reaction to a significant loss. **Anger:** A response to injustice, threat, or frustration. **Fear:** A response to real or perceived danger, preparing for flight or fight. **Surprise:** A reaction to something unexpected, considered the shortest emotion. **Disgust:** The rejection of harmful or repulsive stimuli. **Contempt:** Contempt usually refers to the act of disdain or a general lack of respect for something. In short texts, this will facilitate the personalization of the content recommended to the user. This proposal aligns with studies based on the importance of emotional content along with social media interaction and its influence on user behavior.

Keywords

Artificial intelligence, Natural language processing, Sentiment analysis, Affective computing

1. Introducción

1.1. Introducción

En la actualidad de la era digital, las redes sociales se han convertido en plataformas fundamentales para la interacción entre usuarios, lo que ha llevado a un creciente interés en la personalización y recomendación del contenido propuesto. Sin embargo, gran parte de todo el contenido aún carece de un componente emocional que permita conectar de manera más profunda con los usuarios. Con el aumento de la interacción en las redes sociales, es esencial utilizar tecnologías avanzadas para optimizar la experiencia del usuario (UX), basándose no solo en sus preferencias explícitas, sino también en la comprensión de sus estados emocionales.

El sistema tendrá como objetivo analizar los textos generados por los usuarios, con ayuda de una red social la cual recibirá esos textos y será un insumo para identificar sus emociones a partir de los patrones lingüísticos. Se utilizarán además estos datos emocionales con los cuales, se generará el contenido adaptado a los estados de ánimo que sean detectados, lo que llevará a una mejora en la interacción del usuario y la personalización de su contenido.

En este contexto, la incorporación de modelos de inteligencia artificial y procesamiento del lenguaje natural (PLN) permite capturar y analizar emociones de manera más precisa. Herramientas como pysentimiento ofrecen la capacidad de interpretar los matices emocionales en los mensajes publicados por los usuarios, lo que facilita la creación de sistemas capaces de comprender el contexto emocional y semántico de las interacciones. Esta integración tecnológica contribuye a que las plataformas no solo respondan a lo que el usuario expresa de forma explícita, sino también a lo que transmite de manera implícita a través de su lenguaje.

En este sentido, las recomendaciones personalizadas no solo consideran el historial de interacción del usuario, sino también su estado emocional actual, con el propósito de ofrecer resultados más pertinentes y empáticos. Este tipo de recomendación emocional permite que el sistema anticipe las necesidades afectivas del usuario, brindando contenidos que no solo se ajusten a sus gustos previos, sino que también influyan positivamente en su bienestar y experiencia digital.

Este enfoque se encuentra respaldado por estudios previos que evidencian la efectividad del análisis emocional para personalizar el contenido ofrecido por una red social. El trabajo de Picard [1], resalta el papel crucial de la computación afectiva, señalando su capacidad para transformar la interacción de los usuarios con las plataformas digitales, mejorando la calidad de su experiencia.

1.2. Formulación del Problema

En las redes sociales actuales, aunque la cantidad de contenido generado por los usuarios es masiva y variada, la gran mayoría de contenido carece de una comprensión profunda de las emociones que pueden ser identificadas a través de los textos. Las plataformas sociales no logran captar adecuadamente el estado emocional de los usuarios a partir de sus publicaciones, esto limita la interacción y la creación de contenido.

El vacío en la comprensión emocional en los usuarios, y la falta de un sistema que recolecta información textual a través de un chatbot, Crea una oportunidad para desarrollar un sistema de recomendación más sofisticado que no solo se basaría en preferencias históricas, sino también en el análisis de los sentimientos y las emociones, con el fin de generar contenido emocionalizado que fomente una interacción más significativa.

Como señala Picard [1], “Una de las claves para mejorar la interacción hombre-máquina radica en la capacidad de las máquinas de reconocer y responder a la emociones humanas de los usuarios, lo que permite una mayor conexión y personalización en la experiencia digital”. Sin la incorporación de estos aspectos emocionales, las redes sociales corren el riesgo de perder la capacidad de conectar profundamente con los usuarios, afectando su experiencia y comportamiento en estas plataformas.

1.3. Descripción del problema

El dominio del problema se encuentra en la intersección de las redes sociales, la computación afectiva y el procesamiento de lenguaje natural (NLP). Este se enfocará en plataformas sociales parecidas a facebook e instagram donde los usuarios generaran grandes cantidades de texto en forma de publicaciones. Estos textos contendrán no sólo información explícita sobre los intereses de los usuarios sino también indicios de sus emociones, Las cuales se procesarán correctamente.

La computación afectiva en este contexto se ha destacado como un campo clave, ya que con está se buscará desarrollar un sistema que va a ser capaz de reconocer y responder a las emociones humanas, permitiendo una interacción más natural con las plataformas digitales. Como señala Picard [1], “La computación afectiva tiene el potencial de cambiar la forma en que las máquinas comprenden y responden a las emociones humanas, lo que abre nuevas posibilidades para la creación de experiencias más personalizadas y emocionalmente inteligentes”.

Este desarrollo también se apoyará con el uso de Inteligencia Artificial y modelo de análisis de sentimientos para detectar las emociones como la felicidad, tristeza o sorpresa en textos cortos. Además de estas emociones se busca que el algoritmo pueda identificar también emociones más complejas. De esta forma se integrarán las preferencias de los usuarios en la recomendación de contenido.

Aunque los sistemas de recomendación han evolucionado para sugerir contenido basado en preferencias explícitas y comportamientos históricos, estos sistemas aún no son capaces de comprender emociones más complejas las cuales se generan a partir de las decisiones y la participación del usuario. Sin un análisis adecuado de las emociones, el contenido recomendado a los usuarios puede ser irrelevante y no generar la conexión esperada.

El análisis de emociones a través de texto y recomendaciones de un chatbot, es una tecnología en desarrollo, pero aún no se ha integrado de manera adecuada en los sistemas de recomendación en las plataformas sociales. Esto limita la capacidad de las plataformas al personalizar la experiencia, en función no solo de sus intereses explícitos, sino también de su estado emocional actual. Investigaciones previas han demostrado que el reconocimiento de emociones en el contenido textual puede mejorar la interacción de los usuarios, aumentando el compromiso y satisfacción[2].

“La integración de análisis emocional en los sistemas de recomendación puede mejorar significativamente la experiencia del usuario, ya que les proporciona contenido más relevante y emocionalmente atractivo” [3]. Sin embargo, muchas de las plataformas siguen con insuficiencias de mecanismos robustos para identificar y responder adecuadamente a las emociones expresadas por los usuarios en sus publicaciones.

1.4. Objetivos

1.4.1. Objetivo General

Desarrollar un sistema de recomendación que use computación afectiva y procesamiento de lenguaje natural para generar contenido emocional personalizado en redes sociales.

1.4.2. Objetivos Específicos

1. Caracterizar patrones emocionales presentes en textos mediante algoritmos de procesamiento de lenguaje natural (NLP).
2. Diseñar un chatbot interactivo capaz de recolectar textos en tiempo real y facilitar la interacción con los usuarios en plataformas de redes sociales.
3. Desarrollar e implementar un sistema que analice las emociones en textos mediante técnicas de análisis de sentimientos y computación afectiva, y genere contenido emocional adaptado dinámicamente a los estados emocionales detectados, integrando este modelo con el chatbot.
4. Integrar el sistema con una red social para analizar datos en tiempo real y generar recomendaciones personalizadas
5. Evaluar la funcionalidad del sistema mediante pruebas en un entorno controlado midiendo su efectividad en la interacción personalizada

1.5. Resultados esperados

Objetivo	Resultado Esperado
General	Sistema de recomendación con contenido generado emocionalmente relevante y adaptado para los usuarios.
Caracterizar patrones emocionales presentes en textos mediante algoritmos de procesamiento de lenguaje natural.	Un sistema de análisis emocional que detecte con precisión emociones como alegría, tristeza, ira, miedo, sorpresa, asco o desprecio.
Diseñar un chatbot interactivo capaz de recolectar textos en tiempo real.	Un chatbot funcional que interactúe con los usuarios y recolecte datos textuales.
Desarrollar e implementar un sistema que analice las emociones en textos mediante técnicas de análisis de sentimientos y computación afectiva, y genere contenido emocional adaptado dinámicamente a los estados emocionales detectados, integrando este modelo con el chatbot.	Un sistema que analice emociones en textos y genere contenido emocional dinámico, asegurando una integración eficiente con el chatbot para adaptarse a los estados emocionales detectados.
Integrar el sistema con una red social para analizar datos en tiempo real y generar recomendaciones personalizadas.	Un sistema conectado a una red social que permita analizar publicaciones y comentarios en tiempo real, ofreciendo recomendaciones precisas y personalizadas basadas en el análisis emocional.
Evaluar la funcionalidad del sistema mediante pruebas controladas.	Mejora significativa en la satisfacción y fidelización de los usuarios con las plataformas digitales.

Tabla 1: Resultados Esperados.

Fuente: Elaboración propia

1.6. Justificación

En la actualidad, las redes sociales se han convertido en uno de los principales medios de interacción, expresión y consumo de información para los usuarios. Sin embargo, gran parte del contenido que circula en estas plataformas carece de personalización emocional, lo cual limita la capacidad de las aplicaciones para ofrecer experiencias verdaderamente significativas y empáticas.

Identificar las emociones presentes en los textos publicados por los usuarios representa una oportunidad valiosa para desarrollar sistemas inteligentes que comprendan mejor su estado anímico y generen recomendaciones coherentes con él.

El presente trabajo propone el desarrollo de un sistema de recomendación con generación de contenido emocional para redes sociales, integrando técnicas de procesamiento del lenguaje natural (NLP) y computación afectiva. Esta iniciativa responde a la necesidad de diseñar herramientas tecnológicas que no solo analicen datos, sino que también comprendan el contexto emocional detrás de ellos, permitiendo ofrecer recomendaciones personalizadas de libros, películas o eventos que se alineen con el estado emocional del usuario.

La justificación de este proyecto radica en su aporte tanto tecnológico como social. Desde el punto de vista tecnológico, se plantea una solución innovadora que combina análisis de sentimientos, modelos de detección emocional y motores de recomendación híbridos (como Slope One y modelos de popularidad por emoción), integrados en un chatbot capaz de interactuar en tiempo real con los usuarios. Desde la perspectiva social, la propuesta promueve una interacción digital más humana, empática y responsable, contribuyendo a mejorar la experiencia emocional de los usuarios en los entornos digitales.

Además, el proyecto se fundamenta en la creciente demanda de sistemas inteligentes capaces de adaptarse al contexto emocional y cognitivo de las personas, tendencia respaldada por los avances en inteligencia artificial afectiva. De esta forma, se espera que el desarrollo de este sistema sirva como base para futuras investigaciones y aplicaciones orientadas al bienestar digital y a la personalización de experiencias en línea.

2. Alcance de la Propuesta

El proyecto buscará desarrollar un sistema de recomendación que utilice el procesamiento de lenguaje natural (NLP) , computación afectiva, reconocimiento de emociones, para analizar los textos generados en redes sociales,y a partir de ellos, se busca identificar las emociones principales. Con base en este análisis, el sistema generará contenido emocionalizado para optimizar la interacción y buscará la fidelización del usuario con una personalización del contenido.

2.1. Entrada de datos:

- Utilizará texto generado por los usuarios en formas de post, para analizar emociones principales como alegría, tristeza, ira, miedo, sorpresa, asco o desprecio.
- El chatbot recibirá la entrada de recomendación que pida el usuario, además de aceptar un saludo inicial

2.2. Procesamiento:

El sistema empleará un solo modelo de algoritmo avanzado de NLP, computación afectiva y reconocimiento de emociones, para caracterizar y analizar patrones emocionales en tiempo real.

2.3. Generación de contenido:

El sistema generará recomendaciones que reflejen los estados emocionales detectados, optimizando la personalización y fomentando la interacción de los usuarios a través del chatbot

2.4. Dominio de la solución:

Se enfocará en una red social propia llamada 7social parecida a facebook o instagram, las cuales llegan a procesar un gran volumen de textos en las publicaciones, integrando IA para mejorar la personalización y la experiencia emocional de todos los usuarios. Según Picard(1997), “La computación afectiva tiene el potencial de cambiar la forma en que las máquinas comprenden y responden a las emociones humanas, permitiendo interacciones digitales más naturales e inteligentes”

3. Marco Referencial

3.0.1. Sistemas de recomendación

Los sistemas de recomendación son herramientas fundamentales en las plataformas, como redes sociales y streaming, para personalizar la experiencia del usuario mediante sistemas que analizan un volumen de datos, también con ayuda de algoritmos los cuales buscan predecir las preferencias o necesidades futuras de los usuarios. En un estudio realizado por Ricci et al (2011), se detalla que los sistemas de recomendación tradicionales pueden clasificarse en tres categorías: basados en contenido, colaborativos e híbridos, sin embargo estos modelos no han incorporado el análisis emocional, lo cual limita su capacidad de conectar profundamente con los usuarios [5].

3.0.2. Análisis de sentimientos y computación afectiva

La computación Afectiva, es una subdisciplina de la IA, la cual se centra en el desarrollo de sistemas que puedan reconocer, interpretar y simular emociones humanas. Según Picard (1997), “la computación afectiva permite a las máquinas interactuar de manera más natural con los usuarios al comprender sus estados emocionales, lo que abre nuevas posibilidades para la creación de sistemas de recomendación más efectivos y adaptativos” [1].

Además, Schuller et al. (2013) destaca que “el análisis emocional en textos no solo mejora la precisión de las recomendaciones, sino que también facilita una mayor interacción entre los usuarios y las plataformas, lo que conduce a una experiencia más personalizada” [2].

3.0.3. Impacto de las emociones en la interacción en redes

Las emociones juegan un papel crucial en la forma en que los usuarios interactúan en las plataformas sociales. El trabajo de Kern et al. (2015) sugiere que la personalización emocional puede mejorar significativamente la experiencia de los usuarios, haciendo que se sientan más conectados con el contenido que consumen. Los sistemas que integran el análisis de emociones tienen el potencial de mejorar la satisfacción del usuario al hacer que las recomendaciones sean más relevantes y adaptadas a su estado emocional en ese momento específico [3].

3.0.4. Teoría de las Emociones Básicas de Paul Ekman y su Aplicación en el Análisis de Texto

Paul Ekman, reconocido psicólogo, identificó siete emociones básicas universales: alegría, tristeza, ira, miedo, sorpresa, asco y desprecio [15].

Aunque su investigación se centró inicialmente en las expresiones faciales, la comprensión de estas emociones fundamentales es esencial para el análisis de texto en sistemas de recomendación y computación afectiva.

Al analizar textos, es posible identificar palabras y frases asociadas con estas emociones básicas, lo que permite a los sistemas de recomendación adaptar el contenido según el

estado emocional del usuario. Por ejemplo, textos que contienen palabras relacionadas con la tristeza pueden desencadenar recomendaciones de contenido diseñado para mejorar el estado de ánimo del usuario.

La aplicación de la teoría de Ekman en el análisis de texto implica la creación de diccionarios emocionales y algoritmos de procesamiento de lenguaje natural que detecten y clasifiquen las emociones presentes en el contenido textual. Esta integración mejora la capacidad de los sistemas para ofrecer experiencias más personalizadas y emocionalmente resonantes para los usuarios.

3.0.5. Extensión de las Emociones Básicas al Análisis Semántico en Texto

Aunque Paul Ekman centró gran parte de su trabajo en el reconocimiento de emociones a través de expresiones faciales, sus conceptos fundamentales se han extendido al análisis de texto en sistemas computacionales. Las emociones básicas propuestas por Ekman (alegría, tristeza, ira, miedo, sorpresa, asco y desprecio) han sido la base para el desarrollo de diccionarios semánticos y modelos de aprendizaje automático enfocados en la identificación de emociones en contenido textual [15].

Clasificación Emocional Basada en Texto

La clasificación emocional basada en texto utiliza algoritmos de procesamiento de lenguaje natural (NLP) para detectar emociones en palabras clave, frases y contextos. Por ejemplo:

Alegría: Textos con palabras como "felicidad", "éxito", "amor", son etiquetados con esta emoción.

Tristeza: Textos que contienen términos como "pérdida", "soledad", "desesperación" se clasifican en esta categoría.

Miedo e ira: Analizan patrones de urgencia o amenaza en el lenguaje, lo que es clave para sistemas que monitorean crisis emocionales.

3.0.6. Aplicaciones en Sistemas de Recomendación Al adaptar la teoría de Ekman al análisis de texto:

Se desarrollan sistemas más empáticos, que ofrecen contenido relevante en función del estado emocional detectado. Se mejora la capacidad de las plataformas para personalizar la experiencia del usuario en tiempo real, ya que los algoritmos procesan emociones implícitas en publicaciones, comentarios y mensajes.

Por ejemplo, un sistema podría detectar una publicación como "Me siento agotado y desmotivado hoy" sugerir contenido motivacional o relajante para mejorar el estado emocional del usuario.

Limitaciones y Retos Ambigüedad semántica: La misma palabra puede tener diferentes connotaciones emocionales según el contexto.

Lenguaje no estructurado: Los textos en redes sociales a menudo contienen abreviaturas, errores ortográficos y jerga, lo que complica el análisis.

3.1. Marco Teórico

3.1.1. Teoría de la personalización del contenido

La personalización del contenido se refiere a la capacidad de un sistema para adaptar la información mostrada a un usuario según sus intereses, comportamientos, historial y, cada vez con mayor frecuencia, su estado emocional. Este proceso busca aumentar la relevancia del contenido, mejorar la experiencia de usuario y optimizar el nivel de conexión con la información presentada.

Existen tres estrategias fundamentales de personalización:

1. Personalización basada en contenido (Content-Based Filtering). Analiza las características de los ítems y del usuario para recomendar elementos similares a los consumidos previamente.

2. Filtrado colaborativo. Se basa en patrones de comportamiento de múltiples usuarios. Incluye enfoques basados en usuarios, ítems y variantes como Slope One.

3. Modelos híbridos. Combinan ambas metodologías para corregir debilidades como la dispersión de datos o el problema de *cold-start*.

Dentro de la personalización emocional, el sistema adapta el contenido no solo en función de la interacción o del historial, sino del estado afectivo detectado en tiempo real. Esto se logra integrando análisis de emociones, análisis semántico y retroalimentación afectiva. La literatura evidencia que la personalización emocional incrementa la conexión del usuario y mejora su permanencia en plataformas digitales [6].

3.1.2. Teoría de la computación afectiva

La computación afectiva es un campo de la inteligencia artificial centrado en permitir que las máquinas perciban, interpreten y respondan a las emociones humanas. Su propósito es otorgar a los sistemas la capacidad de interactuar de forma social y emocionalmente inteligente.

Los modelos más estudiados dentro de la computación afectiva son:

1. Modelo PAD (Pleasure–Arousal–Dominance). Define las emociones según tres dimensiones continuas: placer, activación y dominancia. Permite representar emociones complejas y variaciones graduales.

2. Modelo OCC (Ortony, Clore y Collins). Describe las emociones según eventos, agentes y objetos. Es ampliamente utilizado en sistemas multiagente.

3. Clasificación básica de Ekman. Basada en seis emociones universales: alegría, tristeza, ira, miedo, sorpresa y asco. Común en análisis textual y reconocimiento facial.

Variables comunes en estos modelos:

- Activación emocional (valencia y arousal)
- Intensidad emocional
- Contexto lingüístico

- Respuestas fisiológicas (cuando aplica)
- Historial afectivo del usuario

Estrategias de implementación en los trabajos revisados:

1. Reconocimiento de emociones en voz mediante análisis acústico fino.
2. Clasificación emocional de texto utilizando transformers o modelos como Pysentimiento.
3. Uso de emociones para modificar decisiones en sistemas multiagente.
4. Integración de emociones en sistemas de recomendación sociales mediante señales afectivas.
5. Modelos híbridos que combinan afecto con grafos, aprendizaje profundo o similitud estructural.

La computación afectiva proporciona los cimientos para sistemas conversacionales, robots sociales y plataformas de recomendación que ajustan sus respuestas según el estado emocional del usuario [1].

3.1.3. Teoría de la interacción humano-computadora (HCI)

La interacción humano-computadora (HCI) estudia cómo los usuarios interactúan con los sistemas digitales y cómo deben diseñarse dichos sistemas para facilitar una experiencia intuitiva, eficiente y satisfactoria. En su evolución reciente, HCI integra factores emocionales y afectivos, considerando que un sistema capaz de reconocer emociones puede generar interacciones más naturales, disminuir la fricción cognitiva y elevar la satisfacción del usuario.

En este contexto, una interfaz emocionalmente sensible puede adaptar mensajes, colores, respuestas y recomendaciones conforme al estado afectivo detectado [7].

3.1.4. Teoría del análisis de sentimientos

El análisis de sentimientos es una rama del procesamiento del lenguaje natural (NLP) que identifica la polaridad emocional de un texto. Inicialmente empleada para clasificar textos como positivos, negativos o neutros, esta teoría ha evolucionado para abarcar reconocimiento de emociones más finas, tales como alegría, tristeza, ira, miedo o sorpresa.

Los métodos más utilizados incluyen:

- Clasificadores tradicionales (SVM, Naive Bayes)
- Modelos basados en redes neuronales (CNN, LSTM)
- Transformers (BERT, RoBERTa, modelos emocionales en español)
- Librerías especializadas como Pysentimiento para emociones finas en español

Su integración en sistemas recomendadores permite ajustar contenido en función de la emoción detectada en las publicaciones del usuario [8].

3.1.5. Teoría de la motivación social en plataformas digitales

La motivación social explica cómo las emociones influyen en el comportamiento del usuario dentro de plataformas digitales. Las emociones guían decisiones como publicar, reaccionar, comentar y consumir contenido.

Esta teoría establece que:

- Los estados emocionales positivos aumentan la interacción.
- Las emociones negativas incrementan la necesidad de apoyo o expresión.
- La afinidad emocional refuerza la conexión con el contenido.

Cuando un sistema comprende la emoción del usuario, puede mejorar la calidad de sus recomendaciones y promover interacciones más satisfactorias y emocionalmente significativas [9].

3.2. Antecedentes

Los sistemas de recomendación emocional en plataformas sociales, han sido objeto de múltiples investigaciones en los últimos años. Estos proyectos buscan mejorar la interacción entre los usuarios y las plataformas, no solo recomendando contenido basado en intereses explícitos, sino también teniendo en cuenta el estado emocional siendo este identificado a través del análisis de textos generados por los usuarios, lo cual mejora la personalización de las interacciones y refuerza el sistema de recomendación, generando contenido de valor, a continuación se presentan algunos proyectos similares:

3.2.1. Recomendación emocional en plataformas de redes sociales (2019)

Este proyecto se centró en el desarrollo de un sistema que analizaba las emociones de los usuarios a través de sus publicaciones en plataformas como Twitter y Facebook. Usando procesamiento de lenguaje natural (NLP) y análisis de sentimientos, el sistema podría identificar emociones predominantes como felicidad, tristeza o enojo, y recomendar contenido que coincidiera con esos estados emocionales.

Pros: Mejora la personalización del contenido. Permite la conexión emocional entre usuarios y plataformas. Aumenta la interacción del usuario con el contenido recomendado.

Contras: Limitado a emociones explícitas (por ejemplo, no puede detectar emociones complejas como la ambigüedad emocional). Se centra en la recomendación de contenido positivo, dejando de lado las emociones negativas. Consumo elevado de recursos computacionales.

3.2.2. Sistema de recomendación emocional con NLP en aplicaciones de mensajería (2020)

Este proyecto investigó la integración de algoritmos de análisis emocional en plataformas de mensajería instantánea como WhatsApp y Telegram. Utilizando NLP para identificar el tono emocional en los mensajes de texto, el sistema recomendaba respuestas y contenidos emotivos a los usuarios según su estado de ánimo.

Pros: Responde de manera dinámica al estado emocional del usuario. Mejora la calidad de la interacción social mediante respuestas personalizadas. Se integra bien con las plataformas de mensajería existentes.

Contras: La precisión de la detección de emociones aún es imperfecta en mensajes con ambigüedad o sarcasmo. Problemas con la privacidad de los usuarios al analizar sus mensajes. Falta de personalización cultural en el reconocimiento de emociones.

3.2.3. Plataforma de recomendación de contenido emocional con IA (2021)

Este proyecto se desarrolló para plataformas como Instagram y YouTube, donde el sistema de recomendación utiliza IA para analizar imágenes y textos para entender las emociones detrás de los comentarios y publicaciones de los usuarios. Los resultados mostraron que la recomendación de contenido basado en el análisis de emociones podría aumentar la participación en las publicaciones.

Pros: Mejor interacción usuario-plataforma gracias a contenido emocionalmente relevante. Utiliza técnicas avanzadas de IA y NLP, lo que mejora la precisión del sistema. Puede adaptarse a diferentes tipos de contenido (texto, imágenes, videos).

Contras: Requiere una cantidad significativa de datos de usuarios para funcionar.

3.2.4. Computación afectiva para robots de compañía social mediante reconocimiento de emociones del habla de grano fino(2023)

Este proyecto presenta un sistema de computación afectiva diseñado para robots sociales compañeros, utilizando un modelo avanzado de reconocimiento de emociones en voz. El objetivo principal es dotar a los robots de la capacidad de identificar emociones humanas de manera fina y precisa, permitiéndoles responder de forma más empática y natural durante las interacciones. El trabajo propone un modelo de fine-grained speech emotion recognition capaz de distinguir emociones con mayor detalle que los clasificadores tradicionales, lo cual mejora la calidad de la interacción humano-robot.

Los resultados mostraron que utilizar reconocimiento emocional detallado permite que los robots generen respuestas sociales más naturales, adaptadas al estado emocional del usuario, mejorando su funcionalidad en entornos domésticos, de asistencia y de compañía.

Pros: Permite interacciones más naturales y empáticas gracias al reconocimiento de emociones de alta granularidad.

Utiliza técnicas modernas de aprendizaje profundo en audio, mejorando la precisión respecto a métodos clásicos.

Contras: El reconocimiento emocional basado en voz depende fuertemente de la calidad

del audio y del ruido ambiental. Su desempeño puede disminuir en contextos culturales o lingüísticos distintos a los del dataset de entrenamiento.

3.2.5. Sistema Multiagente Afectivo: Modelado y Simulación de los Efectos Sociales y Racionales de las Emociones (2023)

Este proyecto propone un sistema multiagente completamente afectivo, capaz de simular tanto los efectos sociales como los racionales de las emociones dentro de un grupo humano. El modelo integra conceptos de agent-based modelling y sistemas multiagente para recrear cómo las emociones se propagan, influyen en las creencias de los agentes y modifican su comportamiento. Para validar su enfoque, el sistema se aplica al juego UNO, donde seis agentes toman decisiones influenciadas por su estado emocional y por las emociones de otros.

El trabajo demuestra que implementar los cinco mecanismos de interacción emocional —contagio primario, contagio secundario, patrones complementarios, comunicación directa y manipulación— permite reproducir patrones macro característicos del comportamiento humano en grupo. Además, introduce un modelo de estados afectivos basado en PAD (Pleasure–Arousal–Dominance), junto con dinámicas de estatus y relaciones sociales que evolucionan conforme los agentes interactúan.

Pros: Modela de forma detallada la influencia emocional dentro de grupos, incluyendo efectos racionales como cambios en creencias y estrategias. Integra múltiples mecanismos de interacción emocional, lo que permite simular patrones complejos emergentes. Útil para estudiar comportamientos grupales en entornos controlados, como juegos, educación virtual o entornos sociales simulados.

Contras: La dinámica de estatus y relaciones carece de datos empíricos, lo que limita la generalización del modelo. Requiere alta complejidad computacional para simular agentes con arquitectura afectiva completa. Los resultados dependen fuertemente de supuestos subjetivos sobre emociones y parámetros sociales.

3.2.6. Encuesta sobre el método de redes neuronales gráficas bajo recomendación social (2023)

Este estudio presenta una revisión exhaustiva de cómo los Graph Neural Networks (GNN) se han convertido en una técnica central para los sistemas de recomendación social. El artículo analiza cómo la estructura de redes sociales puede ser modelada eficazmente mediante grafos, permitiendo capturar relaciones complejas como amistad, influencia, cercanía y comportamiento conjunto. La revisión muestra que los GNN permiten integrar tanto la información del usuario, como sus conexiones sociales y su historial de interacciones, generando recomendaciones más precisas y personalizadas.

El trabajo compara distintos métodos basados en grafos —incluyendo Graph Convolutional Networks (GCN), Graph Attention Networks (GAT) y modelos de propagación social— destacando sus fortalezas y debilidades en contextos de recomendación. Además, explica cómo los GNN pueden mitigar problemas comunes como la escasez de datos (data sparsity) y el frío inicio (cold-start), usando señales sociales como factor adicional.

Pros: Permite capturar relaciones complejas entre usuarios y su contexto social, mejo-

rando la precisión de las recomendaciones. Los GNN aprovechan señales sociales, lo que ayuda a manejar el problema de data sparsity y del cold-start. Se adaptan bien a sistemas modernos que integran comportamiento social, interacciones y contenido multimodal.

Contras: Los modelos basados en GNN requieren alta capacidad computacional y optimizaciones para escalar con grafos muy grandes. La construcción y actualización del grafo social puede ser costosa en sistemas en producción. Interpretar las recomendaciones generadas por GNN puede ser difícil debido a su naturaleza altamente estructurada y no lineal.

3.2.7. Investigación experimental de modelos de inteligencia artificial para sistemas de recomendación(2025)

Este estudio analiza de forma experimental el rendimiento de varios modelos de inteligencia artificial aplicados a sistemas de recomendación, utilizando dos datasets ampliamente reconocidos: MovieLens-100k y MovieLens-32M. El trabajo compara modelos clásicos y modernos, incluyendo Artificial Neural Networks (ANN), XGBoost, KNNRegressor y LightGBM, evaluando su capacidad para predecir calificaciones de usuario mediante métricas como MAE, RMSE, MAPE, R^2 , así como precisión, recall y F1-Score en diferentes niveles de top-N.

Los resultados muestran que el modelo basado en redes neuronales artificiales (ANN) supera consistentemente a los demás modelos, especialmente en datasets más grandes, donde mejora su rendimiento gracias a su capacidad para aprender patrones complejos en grandes volúmenes de datos. El estudio también evidencia que, aunque modelos como KNNRegressor pueden alcanzar resultados cercanos, su ventaja radica más en la rapidez computacional que en la precisión final.

Este trabajo destaca la importancia de seleccionar modelos adecuados según el tamaño del dataset, las restricciones de procesamiento y el objetivo de precisión, dejando abierta la puerta a futuras investigaciones con Graph Neural Networks (GNN) y redes profundas más avanzadas.

Pros: Comparación detallada entre múltiples modelos clásicos y modernos usados en recomendación. Demuestra que las redes neuronales artificiales mejoran con datasets más grandes, ofreciendo mayor precisión. Utiliza datasets altamente estandarizados (MovieLens), lo que facilita la replicabilidad y comparación con otros trabajos. Evalúa múltiples métricas (MAE, RMSE, MAPE, R^2 , precisión, recall, F1), proporcionando una visión integral del rendimiento.

Contras: El modelo ANN tiene tiempos de entrenamiento elevados y requiere mayor capacidad computacional. El estudio se limita a modelos tradicionales y redes neuronales básicas, sin abordar enfoques más recientes como transformers o GNN avanzadas. Solo se evalúan datasets de calificación explícita, dejando fuera señales implícitas como clicks, visualizaciones o tiempo de interacción. La investigación no profundiza en aspectos de interpretabilidad, cruciales para sistemas de recomendación en producción.

3.3. Términos Comunes

Red social textual	Plataforma donde los usuarios publican únicamente texto, permitiendo un análisis emocional puro sin ruido multimedia.
Análisis emocional (Pysentimiento)	Librería NLP para detectar emociones como alegría, tristeza, enojo, miedo y sorpresa; es el núcleo del modelo emocional.
Modelo emocional	Analiza el texto del usuario, infiere el estado afectivo y lo almacena para generar recomendaciones personalizadas.
Recomendador Slope One	Algoritmo de filtrado colaborativo que predice puntajes, encuentra similitud entre ítems y recomienda contenido basándose en emociones y calificaciones previas.
Generación de contenido afectivo	Usa la emoción detectada para producir recomendaciones coherentes, adaptar contenido textual y generar respuestas emocionales del chatbot.
Chatbot emocional	Interfaz conversacional que interpreta emociones, responde empáticamente y sugiere contenido acorde al estado emocional del usuario.
Publicaciones del usuario	Entradas textuales que alimentan detección de emociones, registro de patrones y retroalimentación del sistema.
Backend (FastAPI)	Procesa solicitudes HTTP/JSON, ejecuta análisis emocional, aplica Slope One, almacena emociones y entrega resultados al frontend.
Almacenamiento emocional local	Guarda emociones detectadas, géneros asociados, títulos recomendados e historial analítico del sistema.
Interfaz cliente (Frontend)	Implementada en React; incluye login, creación de publicaciones, vista del chatbot y consulta de recomendaciones.
Coherencia emocional	Métrica que evalúa si la recomendación coincide con la emoción detectada.
Patrón emocional	Regularidades afectivas detectadas, como tendencia a tristeza, ciclos de alegría o picos de emociones negativas.
Evaluación del sistema	Incluye pruebas de precisión emocional, coherencia recomendadora, percepción de usuarios y comparación con plataformas similares.
Arquitectura Cliente-Servidor	Estructura donde el frontend envía peticiones HTTP/JSON, el backend procesa y la base de datos responde, retornando resultados afectivos en formato JSON.

4. Análisis de modelos y sistemas de recomendación

En esta seccion se lleva a cabo una revisión de la literatura existente sobre sistemas de recomendación y detección de emociones, con el propósito de identificar modelos que puedan ser aplicados en el presente proyecto.

La recopilación comprende un total de 25 artículos, en los cuales se analiza el contexto de aplicación, así como las principales ventajas y limitaciones de los modelos.,A continuacion se presenta una tabla de ejemplo de analisis y modelos de sistemas de recomendacion,debido a la extension el resto se encuentra disponible en formato digital en el siguiente enlace:

<https://drive.google.com/file/d/1GUMLIgeCDOdOB-RBsKc67r2NciCU1YWr/view?usp=sharing>

4.1. Modelos Pros y Contras

Nombre	Año	Autores	Palabra-clave	Técnica de sentimiento	Aportes	Pros y Contras	Técnica de recomendación
Deep-learning based Text Emotion Recognition for Chatbot applications	2020	M. Karna, D. S. Juliet, and R. Joy	Emotion Recognition, Chatbot, Text Emotion, LSTM, Deep Learning	LSTM	1. Conversión del texto en tokens y embeddings. 2. Entrada a red LSTM que mantiene memoria. 3. Actualización de estados y pesos. 4. Clasificación final por capa densa. 5. Asignación automática de emoción.	Pros: Maneja secuencias largas; aprende patrones automáticamente. Contras: Requiere muchos datos; confunde emociones similares.	No menciona técnica específica.
Text-Based Emotion Recognition Using Deep Learning Approach	2022	Santosh K. Bharti et al.	Sentiment Analysis, Emotion Recognition, Deep Learning, NLP	Modelo híbrido (CNN + SVM)	1. Preprocesamiento del texto. 2. CNN extrae características. 3. CNN produce vectores de alta dimensión. 4. SVM clasifica emoción final.	Pros: Mejora la clasificación; combina DL + ML. Contras: Frases cortas pierden contexto; alto costo computacional.	No menciona técnica de recomendación.
Emotion Recognition from Text Based on Automatically Generated Rules	2014	Shadia Shaheen et al.	Emotion Recognition, NLP, Data Mining, ML	Reglas de Reconocimiento de Emociones (ERRs)	1. Análisis sintáctico profundo. 2. Semántica con ontologías. 3. Reglas automáticas de emociones. 4. Uso combinado de PLN y ML. 5. Clasificación en categorías emocionales.	Pros: Considera semántica y sintaxis; usa múltiples clasificadores. Contras: Difícil generar reglas; puede no generalizar a otros idiomas.	Sugiere personalización emocional pero no implementa recomendador.
A Study of Deep Reinforcement Learning Based Recommender Systems	2021	Garima Gupta, Rahul Katarya	DRL, Recommendation Systems, Reward Function, Neural Networks	No aplica (enfoque en recomendación)	1. Modela usuarios como estados únicos. 2. Agente DNN aprende patrones. 3. Recompensas +1/-1 por interacción. 4. Balance entre exploración y explotación.	Pros: Mejora con el tiempo; descubre nuevo contenido. Contras: Alto costo computacional; definir recompensas es difícil; requiere muchos datos.	DRL + DNN para predecir la recomendación y ajustar según recompensa.
Emotional News Recommender System	2015	Ali Hakimi Parizi, Mohammad Kazemifard	News Recommendation, Hybrid Recommender, Sentiment Analysis	Similaridad del Coseno + modelo de Ekman	1. Enfoque híbrido CF + contenido. 2. Busca mejorar estado emocional del usuario.	Pros: Recomienda variado dentro de la misma emoción; mezcla CF + contenido. Contras: Solo 6 emociones básicas; alto costo para análisis en tiempo real.	Recomendador híbrido (contenido + colaborativo).

Tabla 3: Modelos Pros y Contras
Fuente: Elaboración propia.

4.2. Selección Del Modelo

Los modelos basados en deep learning (como LSTM y CNN-SVM), reglas semánticas y sistemas híbridos han demostrado ser efectivos en distintos escenarios:

4.2.1. Modelos emocionales

1.Modelo Ekman: Clasifica emociones en seis categorías básicas (alegría, tristeza, miedo, ira, sorpresa y asco) .

2.Modelo LSTM: Red neuronal recurrente que maneja secuencias largas mediante memoria a largo y corto plazo, útil para detección de emociones en texto .

3.Modelo CNN–SVM: Modelo híbrido que combina redes convolucionales para extraer características y máquinas de soporte vectorial para clasificar emociones .

4.Modelo basado en reglas (ERRs): Utiliza análisis sintáctico y semántico profundo junto con reglas automáticas para reconocer emociones en texto .

5.Pysentimiento (BETO): Librería basada en transformers entrenados en español que clasifica emociones y sentimientos a partir de publicaciones .

4.2.2. Sistemas de recomendación

1.Filtrado colaborativo (Slope One): Método simple que predice calificaciones en base a la diferencia promedio entre ítems; eficiente y fácil de implementar .

2.Filtrado basado en contenido: Recomienda ítems similares a los ya consumidos por el usuario, usando características del contenido .

3.Híbrido (colaborativo + contenido + emoción): Combina detección de emociones con algoritmos de recomendación para diversificar sugerencias y mejorar la precisión

4.Recomendación por popularidad/emoción: Para usuarios nuevos (cold start), usa ítems más calificados por otros bajo la misma emoción detectada .

5.Recomendación multimodal: Integra texto, voz, imágenes y señales fisiológicas para personalizar en función de emociones y datos demográficos .

6.Recomendación demográfica: Usa edad, género o ubicación del usuario para ajustar recomendaciones .

7.Factorización de matrices: Captura patrones latentes complejos para mejorar precisión, aunque con alto costo computacional .

Tras un análisis comparativo de las técnicas anteriores, se ha determinado implementar un modelo híbrido compuesto por:

1.Ekman para detección emocional

2.Slope One para filtrado colaborativo basado en ítems

3.Popularidad por emoción + situación de aleatoriedad como respaldo en situaciones de cold start.

Esta combinación es la mejor opción debido a su capacidad para capturar emociones básicas de manera estructurada y combinar esta información con algoritmos de recomendación eficientes e interpretables por las siguientes razones:

Modelo Ekman El modelo basado en Ekman clasifica las emociones en seis categorías básicas: alegría, tristeza, miedo, sorpresa, asco e ira. Aunque tiene la limitación de no detectar emociones más complejas o ambiguas, ofrece una base sólida y generalizable para la identificación afectiva. Este modelo permite inferir la emoción del usuario al analizar sus primeras tres publicaciones, proporcionando contexto emocional relevante para el sistema de recomendación, además ha sido ampliamente respaldado por investigaciones psicológicas y neurocientíficas. La universalidad de estas emociones ha sido observada en muchas culturas, respaldando la solidez de la teoría de Ekman.

Modelo Slope One Por su parte, el algoritmo Slope One es un método de filtrado colaborativo basado en ítems que calcula la diferencia promedio de calificación entre pares de elementos de recomendación. A diferencia de métodos más complejos, Slope One es fácil de implementar, no requiere entrenamiento previo, y ofrece predicciones personalizadas a partir de las calificaciones mínimas realizadas por el usuario. Esto lo convierte en una opción ideal para sistemas con bases de datos de tamaño moderado, ya que aprovecha de forma eficiente la similitud implícita entre ítems valorados por diferentes usuarios.

Modelo Popularidad por emoción Cuando el sistema no cuenta con suficientes calificaciones por parte de un usuario —lo que comúnmente se conoce como problema de cold start— se recurre al mecanismo de Popularidad por emoción. Este consiste en identificar los ítems más calificados por otros usuarios bajo la misma emoción detectada. De esta forma, el sistema mantiene la coherencia emocional en las recomendaciones y asegura relevancia incluso para usuarios nuevos o con baja interacción.

Comparacion Modelo Híbrido vs Otros modelos A diferencia de modelos basados únicamente en reglas (como ontologías o expresiones regulares), modelos basados en deep learning (como LSTM y CNN-SVM), El modelo Híbrido propuesto, Ekman + Slope One + Popularidad por Emoción + situación de aleatoriedad ofrece una solución flexible, dinámica y ágil. El sistema se adapta al contenido emocional y social de cada usuario, sin depender de estructuras fijas o de grandes volúmenes de datos etiquetados.

Además, este enfoque híbrido evita uno de los grandes problemas de los sistemas tradicionales: la repetición de contenido. Gracias a la combinación de emoción y dinámica colaborativa, las recomendaciones se diversifican dentro de una misma categoría emocional, evitando la fatiga del usuario y promoviendo el descubrimiento de nuevo contenido relevante.

5. Modelo

5.1. Modelo emocional

El modelo emocional consiste en un proceso automatizado de detección y almacenamiento del estado emocional de un usuario, basado en el análisis de sus publicaciones recientes en una red social con ayuda de la librería pysentimiento.

5.1.1. Pysentimiento:

Es una librería de Procesamiento de Lenguaje Natural (NLP) que permite analizar texto en español (y otros idiomas) con el fin de detectar emociones, sentimientos y odio en el discurso. Está basada en transformers que son modelos tipo BERT entrenados en corpus en español, pysentimiento ha demostrado un alto nivel de precisión en la identificación de un amplio rango de emociones, incluidas las emociones básicas. En un estudio de 2022 alcanzó un 80 por ciento de precisión en la detección de emociones en español, superando a otras bibliotecas como TextBlob (75) y SentiStrength (70). Una de las ventajas clave de pysentimiento es su facilidad de uso, ya que dispone de una API clara y sencilla que permite integrar la detección emocional en proyectos sin gran complejidad técnica. Aunque otras bibliotecas como TextBlob y SentiStrength también son relativamente fáciles de usar, suelen requerir configuraciones adicionales o presentan limitaciones en su adaptabilidad.

la librería procesa de la siguiente manera, se recibe el texto a analizar el cual se divide en pequeños tokens o embeddings (palabras divididas o separadas), estos tokens se transforman en vectores numéricos usando un modelo pre entrenado como BERT.

Pysentimiento tiene modelos ya entrenados para distintas tareas:

- 1.Sentiment Analysis (análisis de sentimientos): positivo, negativo, neutro.**
- 2.Emotion Analysis (análisis de emociones): alegría, tristeza, miedo, enfado, etc.**
- 3.Hate Speech Detection (detección de discurso de odio): ofensivo, neutral, etc.**

El modelo seleccionado es el de emotion analysis, el cual predice y funciona como un clasificador automático de emociones y sentimientos en español, el modelo está entrenado sobre grandes volúmenes de texto, lo que resulta en devolver la emoción o sentimiento predominante en un texto con sus probabilidades.

5.2. Modelo generativo de contenido emocional

El presente modelo generativo de contenido emocional constituye una propuesta metodológica para la integración entre el análisis de emociones y los sistemas de recomendación inteligentes. El objetivo principal es generar contenido que esté adaptado al estado emocional del usuario, generando un impacto altamente positivo en las sugerencias.

El proceso inicia con la identificación de la emoción a partir de un análisis emocional, lo cual determina el punto de partida del motor de recomendación. A partir de esta etapa, el sistema selecciona la estrategia adecuada en función del historial y de las interacciones previas de los usuarios.

Dichas estrategias incluyen la generación de recomendaciones aleatorias en ausencia de historial, la priorización por popularidad en casos de emociones similares, y el uso de técnicas de filtrado colaborativo mediante el algoritmo Slope One cuando se dispone de clasificaciones compartidas suficientes.

5.2.1. Comparación de Algoritmos de Filtrado Colaborativo

Algoritmo	Ventajas	Desventajas
k-NN (k-Nearest Neighbors)	Intuitivo y fácil de implementar. Basado en similitud entre usuarios o ítems.	Escalabilidad limitada; requiere cálculos intensivos de similitud en grandes volúmenes de datos.
Matrix Factorization (SVD, etc.)	Alta precisión en grandes conjuntos de datos. Captura patrones latentes complejos.	Entrenamiento costoso; difícil de actualizar en tiempo real; mayor complejidad computacional.
Slope One	Simple, eficiente y fácil de implementar. No requiere entrenamiento complejo. Permite actualizaciones dinámicas en tiempo real.	Menor precisión en datasets muy grandes o dispersos en comparación con técnicas avanzadas.

Tabla 4: Comparación de Algoritmos de Filtrado Colaborativo

Fuente: Elaboración propia.

Tras la comparación, se observa que k-NN presenta limitaciones de escalabilidad, mientras que Matrix Factorization ofrece gran precisión pero a un alto costo computacional y con dificultades para operar en tiempo real. En contraste, Slope One logra un equilibrio entre simplicidad, eficiencia y capacidad de actualización dinámica, lo que lo convierte en la alternativa más adecuada para un chatbot emocional que requiere generar recomendaciones de manera rápida y adaptable al estado del usuario.

5.2.2. Slope One

El algoritmo Slope One fue seleccionado frente a otros métodos de filtrado colaborativo debido a su simplicidad, eficiencia computacional y capacidad de escalabilidad. A diferencia de otras técnicas más complejas como K-NN o Matrix Factorization, Slope One permite realizar predicciones rápidas con un costo computacional reducido, lo que resulta especialmente adecuado para sistemas que requieren respuestas en tiempo real como el chatbot.

El funcionamiento del algoritmo se basa en calcular las diferencias promedio de calificaciones entre pares de ítems. Adicionalmente, estas diferencias se utilizan para estimar la valoración que un usuario podría otorgar a un ítem no evaluado, a partir de sus calificaciones previas. De esta forma, Slope One genera recomendaciones precisas aprovechando patrones colectivos sin necesidad de un entrenamiento costoso.




Figura 1: Algoritmo generativo de contenido emocional
Fuente: Elaboración propia

5.3. Calificación de sentimiento con Pysentimiento

Pysentimiento es un modelo de análisis emocional basado en *transformers* que asigna una probabilidad a cada categoría emocional mediante clasificación multiclase. Cada emoción se expresa en un rango entre 0 y 1, donde el valor más alto corresponde a la emoción dominante. Además del resultado principal, el modelo proporciona la distribución completa de probabilidades para todas las emociones, lo que permite evaluar la ambigüedad emocional del texto.

Para evaluar el desempeño del modelo en el contexto de esta investigación, se realizó un experimento con cinco publicaciones reales de usuarios dentro de la plataforma desarrollada. Cada publicación fue procesada por el modelo *pysentimiento*, obteniendo las probabilidades asociadas a las emociones: *joy*, *sadness*, *anger*, *surprise*, *disgust*, *fear* y la categoría adicional *others*, utilizada cuando el modelo no identifica con claridad una emoción específica.

El procedimiento del experimento consistió en:

1. Seleccionar aleatoriamente cinco textos publicados por distintos usuarios.
2. Procesar cada texto mediante el modelo **pysentimiento**.
3. Registrar la probabilidad generada para cada clase emocional.
4. Identificar la emoción dominante para cada usuario (valor en negrita en la tabla correspondiente).

Es importante destacar que el modelo puede presentar errores cuando el texto es ambiguo, irónico o presenta una combinación emocional compleja, en cuyo caso la probabilidad se distribuye hacia la categoría *others*.

La Tabla se encuentra al final de los anexos, se puede consultar en el siguiente enlace <https://drive.google.com/file/d/1kT67g8ao4fEeCVQQxYcDpP1gLhtT4S2N/view?usp=sharing> y presenta los resultados obtenidos en notación científica con cinco decimales, mostrando la probabilidad asignada a cada emoción para los cinco usuarios evaluados.

5.4. Patrones clave identificados en publicaciones analizadas

5.4.1. Usuario 1: Emocion: Joy

Publicación	Patrón identificado	Tabla base
“Estoy muy agradecido con dios...”	Expresiones de gratitud	“agradecido”, “feliz” → joy
“Hoy logré terminar mi proyecto...”	Satisfacción personal (feliz, logro)	“me siento feliz” → joy
“El clima está perfecto para...”	Disfrutar del momento	Implícito en patrón de alegría

Tabla 5: Patrones clave identificados en Joy

Fuente: Elaboración propia.

5.4.2. Usuario 2: Emocion: Surprise

Publicación	Patrón identificado	Tabla base
“¡Qué sorpresa tan increíble!”	Sorpresa positiva	“gran sorpresa” → surprise
“Estábamos en shock...”	Resultados inesperados	“no lo esperaba” → surprise
“Nos quedamos sin palabras...”	Asombro	“no lo podía creer” → surprise

Tabla 6: Patrones clave identificados en Surprise

Fuente: Elaboración propia.

5.4.3. Usuario 3: Emocion: Sadness

Publicación	Patrón identificado	Tabla base
“me siento un poco desanimado”	Estado emocional bajo	“todo se siente vacío” → sadness
“la soledad me pesa últimamente”	Soledad	“me siento solo” → sadness
“he estado reflexionando mucho”	Reflexión personal	“he estado pensando...” → sadness

Tabla 7: Patrones clave identificados en Sadness

Fuente: Elaboración propia.

5.4.4. Usuario 4: Emocion: Anger

Publicación	Patrón identificado	Tabla base
“No puedo creer que aún no solucionen...”	Queja persistente	“no soporto...” → anger
“Estoy cansado de tener que repetir...”	Frustración constante	“estoy cansado de...” → anger
“Uno espera respeto como cliente.”	Exigencia de trato justo	“me molesta que...” → anger

Tabla 8: Patrones clave identificados en Anger

Fuente: Elaboración propia.

5.4.5. Usuario 5: Emocion: Fear

Publicación	Patrón identificado	Tabla base
“Me da miedo que algo malo...”	Inseguridad familiar	“me da miedo...” → fear
“Siento que alguien me sigue...”	Amenaza externa	“siento que algo malo pasará” → fear
“Tengo pesadillas constantes...”	Ansiedad nocturna	Implícito en temor
“Siento un pánico terrible...”	Terror directo	“no me sentí seguro...” → fear
“Vi una sombra moverse...”	Miedo irracional / percepción	Aplica a miedo intenso

Tabla 9: Patrones clave identificados en Fear

Fuente: Elaboración propia.

5.5. Algoritmo del Modelo Emocional

Entrada: El usuario publica contenido Mínimo 3 post.

Procesamiento: 1.Se consulta el nombre del usuario por su user-id.

2.Se obtienen las publicaciones recientes del usuario desde la API.

3.Se combinan los textos y se analiza la emoción predominante usando pysentimiento.

4.Se guarda la emoción detectada (alegría, tristeza, miedo, etc.) en estado-emocional.json

Salida: (consumo por recomendador): 1.El chatbot carga el archivo estado-emocional.json.

2.Recupera la emoción del usuario y la usa para generar recomendaciones personalizadas.

Requisito funcional: Detectar la emoción del usuario automáticamente mediante sus publicaciones.

Requisito no funcional: El modelo debe procesar texto en español, ofrecer resultados en el menor tiempo posible y almacenar el estado emocional en un formato persistente.

Validación: Se prueba con varios usuarios y sus publicaciones. El sistema logra detectar la emoción correctamente.




Figura 2: Algoritmo del modelo emocional

Fuente: Elaboración propia

5.6. Justificación del modelo

El uso de la librería pysentimiento se justifica debido a su capacidad para realizar análisis de sentimientos y emociones en lenguaje natural con alta precisión, especialmente en idioma español.

A diferencia de otras herramientas genéricas, pysentimiento está entrenada con modelos de transformers como BERTin y BETO, optimizados para interpretar las particularidades lingüísticas, semánticas y contextuales del español, lo que garantiza resultados más coherentes y adaptados al entorno del usuario. Esta librería permite detectar emociones básicas como alegría, tristeza, enojo, miedo o sorpresa a partir de textos cortos, facilitando la integración directa con el chatbot del sistema.

Por otra parte, la implementación de un modelo emocional complementa esta herramienta al estructurar los resultados del análisis en categorías afectivas reconocidas, basadas en la teoría de las emociones básicas de Paul Ekman. Dicho modelo actúa como un puente entre la comprensión lingüística y la generación de contenido emocionalizado, permitiendo que el sistema de recomendación responda de manera empática y adaptativa a los estados de ánimo detectados.

La combinación de pysentimiento con el modelo emocional no solo mejora la precisión del reconocimiento afectivo, sino que también posibilita una personalización más profunda en la interacción con los usuarios. Este enfoque contribuye a humanizar los sistemas de recomendación, integrando inteligencia artificial con comprensión emocional, lo cual representa un avance significativo en el campo de la computación afectiva y la interacción humano-computadora (HCI).

5.7. Requisitos Funcionales del chatbot

Los requisitos funcionales del chatbot definen las capacidades esenciales que el sistema debe cumplir para responder de manera adecuada a las necesidades del usuario. En este caso, el chatbot no solo debe mantener un desarrollo fluido, sino también integrar análisis de emociones, de modo que las recomendaciones ofrecidas (libros, películas o eventos) se adapten al estado emocional detectado. Estos requisitos aseguran que el chatbot pueda interactuar de forma personalizada, detectar emociones automáticamente y generar respuestas o recomendaciones relevantes que mejoren la experiencia de uso.

Funcionalidades clave:

ID	Requisito Funcional	Descripción
RF1	Validación de publicaciones mínimas	Solo se permitirá el acceso al chatbot a usuarios que hayan realizado al menos 3 publicaciones.
RF2	Visualización del chatbot	El chatbot debe mostrarse como ventana flotante en la aplicación React, accesible mediante un botón toggle.
RF3	Detección de emoción predominante	El backend debe enviar al chatbot la emoción predominante y mostrarla al iniciar el chat.
RF4	Entrada textual	El chatbot debe permitir al usuario escribir saludos o pedir recomendaciones en la caja de chat.
RF5	Entrada errónea	Si el usuario pide algo distinto a recomendaciones, debe responder: "Lo siento, solo puedo recomendar libros, películas o eventos según tu emoción", sin inventar información.
RF6	Recomendación personalizada	El sistema debe mostrar una recomendación basada en la emoción detectada y el tipo seleccionado (libro, película o evento).
RF7	Recomendación aleatoria	Si no existen recomendaciones populares aún, se debe mostrar una recomendación aleatoria.
RF8	Recomendación por popularidad y emoción	Se debe mostrar una recomendación popular si existen favoritos o ítems populares para la emoción del usuario.
RF9	Recomendación colaborativa (Slope One)	Si el usuario ha calificado al menos dos ítems populares con calificación mayor o igual a 4, se generan recomendaciones con Slope One.

ID	Requisito Funcional	Descripción
RF10	Evaluación de recomendación	El usuario podrá calificar la utilidad (1–5 estrellas). Si es mayor o igual a 4 se guarda como útil; si no, se descarta.

Tabla 10: Requisitos Funcionales del Chatbot

Fuente: Elaboración propia

5.8. Diagrama UML: Casos de Uso

El diagrama de casos de uso permite representar de manera gráfica las principales interacciones entre el usuario y el sistema del chatbot emocional. En este caso, se identifican los procesos clave que garantizan el funcionamiento esperado: desde el inicio de sesión y la consulta de publicaciones, hasta el análisis de emociones y la generación de recomendaciones personalizadas.

Así mismo, se contempla la posibilidad de que el usuario visualice las recomendaciones ofrecidas y otorgue una calificación, lo cual enriquece el sistema al retroalimentar su funcionamiento. De esta forma, el diagrama proporciona una visión clara y estructurada de los servicios esenciales que el chatbot debe ofrecer al usuario.




Figura 3: Diagrama de casos de uso

Fuente: Elaboración propia

Actores: Usuario

Casos de Uso:

Iniciar sesión: Permite al usuario autenticarse en el sistema para acceder a las funcionalidades del chatbot.

Consultar publicaciones: El usuario escribe sus publicaciones que servirán de base para el análisis.

Analizar emoción: El sistema detecta la emoción predominante en las publicaciones del usuario.

Solicitar recomendación: El usuario pide al chatbot una sugerencia basada en la emoción detectada.

Ver recomendación: El sistema muestra la recomendación personalizada (libro, película o evento).

Calificar recomendación: El usuario evalúa la recomendación recibida para mejorar futuras sugerencias.

5.9. Arquitectura de diseño del chatbot

La arquitectura del chatbot se basa en un diseño modular que permite la integración de diferentes componentes de manera flexible y escalable. El sistema está compuesto por las siguientes capas y módulos principales:

1.Interfaz de Usuario (Frontend):

- 1.1 Permite la interacción directa con el usuario a través de una aplicación web.
- 1.2 Gestiona la visualización de mensajes, recomendaciones y formularios de calificación.
- 1.3 Uso de streamlit para la interfaz del chatbot

2.Gestor de Conversación (Chat Engine):

- 2.1 Administra el flujo del diálogo con el usuario, el cual es cerrado para no desviarse del objetivo principal del chatbot.
- 2.2 Controla los casos de uso principales:saludo, solicitud de recomendación y petición errónea

3.Módulo de Análisis Emocional:

- 3.1 Implementado con bibliotecas como pysentimiento. Solo se muestra en la interfaz del chat la emoción predominante, pero es procesada desde el API de backend

4.Motor de Recomendación:

- 4.1 Integra técnicas de recomendación híbridas, Basadas en aleatoriedad, Basadas en Popular , Basadas en filtrado colaborativo basado en ítems.
- 4.2 Recupera información de fuentes externas para las recomendaciones(APIs como **Google Books** para libros, **OMDb** para películas y **Ticketmaster** para los eventos).

5.Capa de Datos y Persistencia:

- 5.1 Almacena usuarios, calificaciones y asociaciones en estructuras como json, bases de

datos relacionales o en nube.

5.2 Permite mantener el historial de interacciones para mejorar la personalización.

6.Servicios Externos y APIs:

6.1 Conexión con servicios de terceros para enriquecer las recomendaciones con detalles como sinopsis, imágenes y metadatos.

Esta arquitectura asegura separación de responsabilidades, escalabilidad y facilidad de mantenimiento, además de permitir que el chatbot evolucione incorporando nuevos algoritmos o fuentes de información sin afectar la estructura global del sistema.




Figura 4: Arquitectura de diseño del chatbot
Fuente: Elaboración propia

5.10. Interfaz del chatbot

Se realiza la integración de un chatbot con el objetivo de ofrecer una experiencia fluida y acorde con el usuario, para hacer efectiva la recomendación de contenido relacionado con su estado de ánimo, fortaleciendo la pertinencia y utilidad de las recomendaciones.

Para evitar distracciones y mantener el foco en el propósito principal de recibir recomendaciones, el bot solo saluda y recibe peticiones de recomendación por medio de la caja del chat, de otra manera si se trata de desviar el chatbot recuerda que solo debe recomendar libros, películas o eventos por lo cual restringe el uso de conversación abierta dentro del chatbot. De esta manera, se guía al usuario en un flujo controlado y coherente con su objetivo.

El chatbot fue implementado utilizando el framework Streamlit, el cual permite construir interfaces interactivas de manera rápida y eficiente en Python. Gracias a su capacidad para manejar entradas dinámicas, integrar análisis de datos y ofrecer una visualización clara, Streamlit resultó adecuado para este prototipo.



Figura 5: Interfaz Principal del chatbot
Fuente: Elaboración propia




Figura 6: Saludo y respuesta del chatbot
Fuente: Elaboración propia




Figura 7: Peticion de recomendacion
Fuente: Elaboración propia

Recomendacion

Este componente muestra una recomendación personalizada de libro en una interfaz visual oscura y minimalista, destacando el título "La furia del silencio" junto al nombre del autor, Carlos Dávalos.

La portada del libro se presenta de forma destacada con bordes redondeados, acompañada por una breve descripción que busca despertar el interés del usuario.

Todo el diseño está pensado para mantener la atención en la recomendación, con un estilo limpio, contrastes bien definidos y elementos visuales organizados que refuerzan una experiencia de lectura clara y atractiva.

Puntuacion

Después de recibir la recomendación emocional, el usuario la calificó con un 4 sobre 5, lo cual indica que la encontró bastante útil y alineada con su estado de ánimo.

Esta puntuación refleja una experiencia positiva y sugiere que el sistema logró ofrecer un contenido que, aunque no perfecto, resultó relevante y satisfactorio para el usuario.

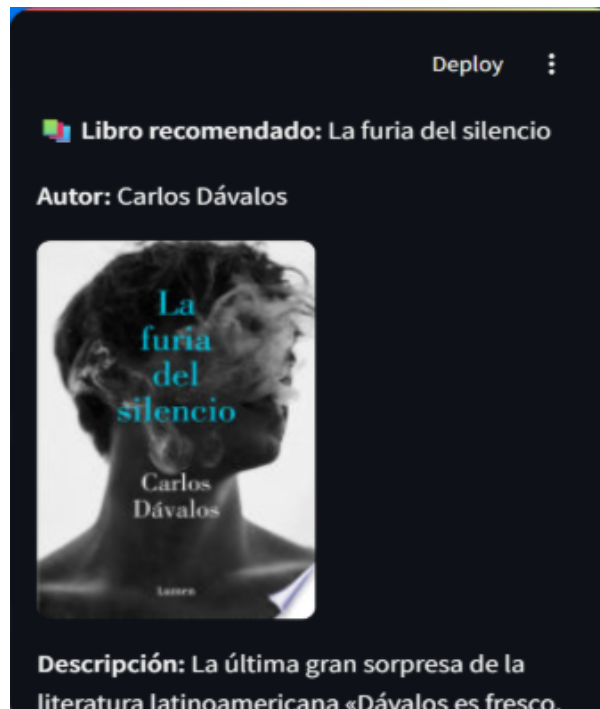


Figura 8: Vista de Recomendacion
Fuente: Elaboración propia




Figura 9: Vista de la calificacion
Fuente: Elaboración propia

6. Desarrollo Del Proyecto

En este capítulo se presentan los elementos más significativos del proceso de implementación, describiendo las estrategias empleadas, el lenguaje de programación seleccionado y la estructura general del aplicativo. Asimismo, se aborda la gestión de la seguridad de los datos y la configuración del usuario. Para el desarrollo de la solución propuesta, fue necesario diseñar e implementar una arquitectura web que garantizara su funcionamiento y escalabilidad.

6.1. Entorno de Desarrollo

Se propone un sistema web, de recomendación y análisis de sentimientos que tiene como objetivo optimizar la interacción de los usuarios en plataformas digitales mediante la generación de contenido emocional basado en el análisis de texto. Utilizando tecnologías avanzadas como IA, Procesamiento del lenguaje natural(NLP), y Computación afectiva, se busca mejorar la experiencia, el sistema identificará y analizará estos datos en busca de identificar emociones simples.

6.2. Tecnologías y Frameworks a Implementar

Lenguaje de programación: Python, seleccionado por su amplia cantidad de herramientas y manejo de servicios.

Tecnologías Web: HTML, CSS, JavaScript.

Gestor de Base De Datos: PostgreSQL en la nube.

1. Frontend: React con Vite

Vite con React es una biblioteca de JavaScript que sirve para la creación de interfaces de usuario atractivas, especialmente adecuadas para aplicaciones que requieren alta interactividad y experiencia dinámica. Con React se desarrollará la interfaz del chatbot y la plataforma de red social, aprovechando la modularidad y reutilización de componentes.

2. Backend: FastAPI

FastAPI es un framework web moderno y de alto rendimiento para construir API en Python. Fue diseñado para aprovechar las capacidades más recientes de Python, como las *type hints*, y se basa en Starlette (para la gestión de solicitudes asíncronas) y Pydantic (para validación de datos y serialización).

Características principales:

1. Alto rendimiento:

- Utiliza ASGI para manejar solicitudes asíncronas.
- Comparable en velocidad a frameworks como Node.js o Go.

2. Validación automática de datos:

Gracias a Pydantic, valida los datos de entrada y salida automáticamente según los esquemas definidos.

3. **Documentación automática:** Genera documentación interactiva con Swagger UI y ReDoc.
4. **Compatibilidad con type hints:** Mejora legibilidad y mantenibilidad del código.
5. **Soporte para asincronía:** Permite operaciones asíncronas usando `async` y `await`.
6. **Escalabilidad:** Capaz de manejar miles de solicitudes simultáneas.
7. **Extensible:** Integración con bases de datos y bibliotecas como SQLAlchemy o Tortoise ORM.

6.3. Procesamiento de Texto y Sistema de Recomendación

El procesamiento del sistema se centra en analizar los textos de los usuarios para identificar emociones y generar recomendaciones personalizadas. Se implementaron técnicas de NLP y computación afectiva usando Python.

Librerías y herramientas utilizadas:

- **pysentimiento:** Clasificación de emociones básicas (alegría, tristeza, ira, miedo, sorpresa, asco, desprecio) y cálculo de probabilidades asociadas.
- **spaCy:** Procesamiento lingüístico avanzado: tokenización, lematización, etiquetado POS y reconocimiento de entidades.
- **NLTK:** Preprocesamiento complementario: limpieza de texto, eliminación de stopwords y normalización.
- **pandas y NumPy:** Manejo de datos y cálculos estadísticos.

Flujo del procesamiento:

1. **Preprocesamiento:** Normalización de caracteres, eliminación de signos de puntuación y stopwords, lematización.
2. **Detección de emociones:**
 - Uso de **pysentimiento** con modelo preentrenado **roberta-base-spanish**.
 - Threshold de confianza: 0.5 para determinar la emoción predominante.
 - Salida: vector de probabilidades por emoción; la mayor indica la emoción dominante.
3. **Validación contextual:** SpaCy analiza la sintaxis y contexto, complementando la predicción con reglas heurísticas.
4. **Integración en recomendaciones:** La emoción predominante se combina con métricas de popularidad y similitud de usuarios (filtrado colaborativo) para personalizar el contenido recomendado.

Consideraciones y Salida Final:

- Balance entre precisión y eficiencia, evitando modelos demasiado pesados.
- Manejo de textos vacíos o ambiguos asignando la etiqueta *Others*.
- Salida final: JSON con `usuario_id`, `texto_analizado`, `emocion_predominante` y `probabilidades_emociones`.
- Esta información se usa para:
 - Visualización de análisis emocional.
 - Ajuste dinámico de recomendaciones.
 - Evaluación de coherencia emocional del sistema.

6.4. Estructura de Base de datos

El manejo de los títulos de las recomendaciones, las emociones registradas y la utilidad de las recomendaciones se guardan de manera local en archivos json, por lo cual la estructura de la base de datos se simplifica en 2 tablas:

User

En esta tabla se almacenan los datos con los cuales se registra el usuario en la aplicación, por lo cual cuenta con los siguientes atributos:

id: identificador de la tabla; es la llave primaria y corresponde a un valor entero.

name: nombre completo del usuario, variable de tipo string.

username: nombre de usuario único con el que se autentica dentro de la aplicación, variable de tipo string.

email: almacena la dirección de correo electrónico del usuario, variable de tipo string.

age: edad del usuario, variable de tipo integer.

password: contraseña del usuario, variable de tipo string.

User Está relacionada mediante llaves foráneas con la tabla **Post**, permitiendo establecer la conexión entre los usuarios y las publicaciones que se crean dentro de la aplicación.

Post

En esta tabla se almacenan las publicaciones realizadas por los usuarios. Cuenta con los siguientes atributos:

id: identificador de la tabla; es la llave primaria y corresponde a un valor entero.

title: título de la publicación, variable de tipo string.

content: contenido del texto de la publicación, variable de tipo string.

user-id: referencia foránea que enlaza la publicación con el usuario que la creó, proveniente de la tabla **User**.

Post se relaciona con **User** mediante una llave foránea (**ForeignKey**), lo que permite acceder a los datos del usuario que generó la publicación.

6.5. APIs Externas integradas

Con el fin de enriquecer el sistema de recomendación y ofrecer resultados más personalizados, se integraron diferentes APIs externas que permiten acceder a información actualizada y detallada sobre libros, películas y eventos.

Estas herramientas aportan datos confiables y variados que complementan el análisis de emociones, garantizando que las recomendaciones no solo sean coherentes con el estado emocional del usuario, sino también relevantes y atractivas en contenido.

Google Books API:

Permite acceder a una amplia base de datos de libros, proporcionando información sobre títulos, autores, descripciones, portadas y reseñas. Gracias a esta API es posible recomendar lecturas ajustadas a las emociones detectadas y presentar al usuario opciones variadas acompañadas de detalles contextuales.

OMDb API:

Es una API abierta que ofrece información sobre películas y series, incluyendo sinopsis, elenco, año de estreno, género, valoraciones y portadas. Su integración permite generar recomendaciones cinematográficas precisas, con base en la emoción predominante del usuario y en los metadatos de cada producción.

Ticketmaster API:

Proporciona acceso a información sobre eventos en vivo, como conciertos, espectáculos y actividades culturales. A través de esta API se generan sugerencias de eventos alineados con las emociones detectadas, además de mostrar datos prácticos como fecha, ubicación y disponibilidad de entradas.

Cohere API:

Se integra con el propósito de potenciar el componente de generación de contenido emocional. Cohere utiliza modelos avanzados de lenguaje natural (LLM) que permiten interpretar el contexto semántico y generar textos coherentes, empáticos y adaptados al estado emocional del usuario. Su implementación mejora la calidad de las respuestas del chatbot, permitiendo una interacción más natural y fluida.

Streamlit API:

Se utiliza como plataforma de despliegue interactiva para la visualización y ejecución del sistema de recomendación por chatbot. Streamlit facilita la creación de interfaces web dinámicas en Python, permitiendo integrar el modelo emocional, el análisis de texto y las recomendaciones en un mismo entorno accesible. Su incorporación se justifica por su rapidez de implementación, compatibilidad con bibliotecas de inteligencia artificial y capacidad para mantener estados de sesión (*st.session-state*), lo que garantiza una experiencia continua y personalizada para el usuario.

6.6. Tabla Comparativa de IA

Inteligencia Artificial (IA)	Características principales	Observaciones y motivo de selección
GPT (OpenAI)	Modelo de lenguaje de gran escala, muy preciso en generación de texto y comprensión contextual. Requiere API de OpenAI y tiene costos elevados.	Gran comprensión pero limitado por costos y políticas de uso.
Cohere	Modelo enfocado en generación contextual y análisis semántico. Con soporte nativo en español y funcionalidades de clasificación y embeddings.	Seleccionado porque ofrece buen rendimiento, accesibilidad y personalización para generación emocional en español.
LLaMA (Meta AI)	Modelo abierto de alta calidad, pero exige hardware potente para correr localmente.	Flexible, pero poco viable para una aplicación ligera en producción.
DeepSeek	Modelo fuerte en razonamiento lógico pero con soporte limitado para español.	Buen análisis, pero integración más compleja y menos optimizado para generación emocional contextual.

Tabla 11: Comparación de modelos de Inteligencia Artificial Generativa

Fuente: Elaboración propia.

6.7. API's Red Social

En la siguiente sección vamos a realizar una comparación entre las posibles opciones de selección de la API de la red social (por ejemplo, Twitter, Facebook, Instagram, o la propia red social 7social). Con el objetivo de analizar publicaciones de feeds de redes sociales en tiempo real y generar recomendaciones personalizadas buscando a su vez la retroalimentación y experiencia recolectada a través de los usuarios.

Tabla Comparativa breve entre APIs

Red Social	Ventajas Clave	Consideraciones
Twitter	API muy robusta, popular	Requiere tokens, está más restringida y con cuotas.
Facebook / Instagram	Amplia información y métricas disponibles	Requiere validación de permisos y filtros complejos.
Mastodon	Acceso libre, API REST simple, sin restricciones	Menos restricciones, requiere token. Sirve para pruebas sin fricciones.
7Social	Control total sobre los datos, sin restricciones externas	Sin cuotas ni uso de token, perfecto para pruebas sin fricciones.

Tabla 12: Comparativa entre APIs de red social.

Fuente: Elaboración propia.

A pesar de que redes sociales como Twitter, Facebook o Instagram cuentan con gran cantidad de datos personales, presentan implicaciones importantes en materia de seguridad, privacidad y libertad de expresión. Además, sus APIs están sujetas a políticas estrictas de acceso, con limitaciones en las consultas, costos asociados y necesidad de aprobaciones adicionales.

En contraste, la red social propia 7Social representa una ventaja estratégica significativa. Al ser un entorno controlado, no existen restricciones externas en el acceso a datos ni dependencias de terceros. Esto garantiza mayor flexibilidad, seguridad y libertad en el manejo de la información, permitiendo personalizar tanto la API como las políticas de uso de acuerdo con las necesidades del proyecto. No obstante, se reconoce que al tratarse de una red en desarrollo, 7Social enfrenta retos relacionados con la escalabilidad, el mantenimiento y la validación de su adopción por parte de los usuarios.

Selección

Para este proyecto, se plantea utilizar 7Social con el fin de realizar un análisis comparativo. De esta forma, será posible determinar cuál de las dos alternativas resulta más conveniente: Mastodon, por su apertura y descentralización; o 7Social, por el control total y la capacidad de personalización que ofrece al ser una plataforma propia.

Observacion

Para entrenar el modelo emocional se debe destacar que se utilizo mastodon al igual que las pruebas realizadas para contrastar resultados y compararlos con los resultados obtenidos de la seleccion de la red social propia 7Social

6.8. Implementacion de la aplicacion

La implementación de la aplicación se realizó con base en el comportamiento esperado del sistema, abarcando desde la autenticación y gestión de usuarios hasta la interacción con el chatbot emocional y la generación de recomendaciones personalizadas. El desarrollo integra procesamiento de lenguaje natural, análisis emocional y conexión con diversas APIs externas, permitiendo una experiencia interactiva, empática y coherente con el estado emocional del usuario.

6.9. Requerimientos Funcionales

Registro e Inicio de Sesión

Los usuarios pueden registrarse ingresando su nombre, correo electrónico, edad, nombre de usuario y contraseña. El sistema permite el inicio de sesión mediante credenciales válidas, garantizando la autenticación y el acceso seguro a las funcionalidades del sistema.

Manejo de Sesiones

La aplicación utiliza un sistema de manejo de sesiones que permite rastrear la actividad de los usuarios autenticados. Esto se logra mediante la gestión del estado de sesión en Streamlit (`st.session-state`), lo que asegura coherencia en las recomendaciones y persistencia en las interacciones con el chatbot.

Gestión de Publicaciones

Los usuarios pueden escribir publicaciones en el feed de la red social. Esta información se almacena en la base de datos para analizar el texto y extraer la emoción predominante con lo cual se personaliza las sugerencias futuras y mejora el aprendizaje del sistema.

Chatbot Emocional

El chatbot integra Cohere API para generar respuestas contextuales y empáticas, manteniendo la coherencia semántica con la emoción detectada. El flujo conversacional se gestiona mediante estados de diálogo, permitiendo mantener el contexto durante toda la interacción y generar recomendaciones acordes a las requeridas por el usuario

Recomendaciones Personalizadas

El sistema genera recomendaciones de libros, películas o eventos basadas en la emoción actual del usuario y su historial de interacción. Para ello, se utilizan las siguientes APIs externas:

Google Books API: recomendaciones de libros relacionadas con el estado emocional.

OMDb API: sugerencias de películas basadas en la emoción predominante.

Ticketmaster API: eventos en vivo y actividades culturales coherentes con el estado emocional detectado.

El algoritmo de recomendación combina información emocional con datos de popularidad y afinidad del usuario para ofrecer resultados más precisos, además de implementar filtros para evitar la repetición de las recomendaciones evitando la fatiga del usuario.

Interfaz de Usuario (UI)

La aplicación cuenta con una interfaz desarrollada en Streamlit, que ofrece una experiencia interactiva, simple y clara. Presenta las emociones detectadas, las respuestas del chatbot y las recomendaciones generadas, además de permitir al usuario calificar los ítems y visualizar su historial de chat.

Integración con Librerías Externas

Se integran librerías como pysentimiento para el análisis emocional, spaCy para el procesamiento lingüístico, requests para la comunicación con las APIs. Estas herramientas permiten procesar texto, generar respuestas coherentes y estructurar la información de manera eficiente.

Integración con APIs Externas

La aplicación se conecta con Google Books, OMDb, Ticketmaster y Cohere, garantizando un acceso continuo a datos actualizados y contenido relevante. Cada API complementa una dimensión distinta de la recomendación: lectura, cine, eventos y respuesta emocional.

Manejo de Errores

El sistema maneja errores y excepciones durante la conexión con las APIs y el análisis de texto. En caso de fallas, se presentan mensajes informativos al usuario sin interrumpir la ejecución general de la aplicación.

Seguridad

Las contraseñas de los usuarios se almacenan en forma cifrada. Además, se implementan validaciones de entrada y control de sesión para proteger los datos personales. Streamlit se configura para restringir accesos no autorizados, y la comunicación con las APIs se realiza mediante protocolos seguros.

6.10. Control De Flujo - Modelo BPMN básico

El modelo BPMN básico es aquel que representa, de manera gráfica y estructurada, el flujo principal de interacciones entre el usuario y el prototipo de sistema de recomendación. Su objetivo es describir las actividades esenciales del chatbot, desde el inicio de sesión hasta la obtención y calificación de recomendaciones. A través de este diagrama se facilita la comprensión de los procesos, roles y decisiones involucradas, proporcionando una visión clara y simplificada del funcionamiento del sistema.





Figura 10: Control de flujo - Modelo BPMN basico
Fuente: Elaboración propia

Descripcion del flujo:

1. Usuario accede al sistema.
- 2.El Sistema verifica si ha iniciado sesión.
- 3.Se verifica si tiene al menos 3 publicaciones en la plataforma →
[Si] Se Realiza el análisis de la emocion en las publicaciones
[No] No se realiza el analisis
- 4.Analiza la emoción desde las publicaciones usando pysentimiento.
- 5.Muestra chatbot widget (interfaz Streamlit embebida) →
[Si] Usuario Visualiza la emoción predominante y la caja de chat para interactuar con el chatbot ademas de la interfaz
[No] Mensaje de error.
- 6.Usuario escribe saludo o recomendacion con el tipo en la caja de chat del chatbot →
[Si] Saludo Cordial , recomendacion Aleatoria si no ahi popular por emocion, recomendacion Popular por emocion.
[No] Mensaje : "Lo siento , solo puedo recomendar libros, peliculas o eventos segun tu emocion" nunca debe inventar informacion ni hablar de otros temas.
- 7.El Sistema verifica si puede usar recomendacion por colaborativa Slope One verificando que el usuario halla calificado mas de 2 recomendaciones populares.→
[Si] Genera la recomendacion colaborativa
[No] Genera la recomendacion popular
- 8.Se genera la recomendacion respectiva, ahora se analiza si el usuario califica la recomendacion con mas de 4 estrellas.→
[Si] Se guarda en un archivo para generar recomendaciones populares y el flujo llega a su fin.
[No] Se ignora y el flujo llega a su fin


Flujo Red Social

- 1.Cuando un usuario visita la aplicacion, se encuentra con la opcion de iniciar sesion o registrarse.
- 2.Despues del registro, se almacena la informacion del usuario en la base de datos y se devuelve al inicio de sesion por lo cual se debe colocar las credenciales para iniciar sesion ya que no se redirecciona automaticamente.
- 3.Despues de iniciar sesion, el usuario es dirigido a la interfaz de feed de La red social, donde el usuario publica minimo 3 post y despues oprime el boton del chat para abrir e interactuar con el chatbot
4. Luego una vez abierto el chatbot se escribe un saludo y se pide la recomendacion




(a) Inicio de sesión

Fuente: Elaboración propia



(b) Registro

Fuente: Elaboración propia



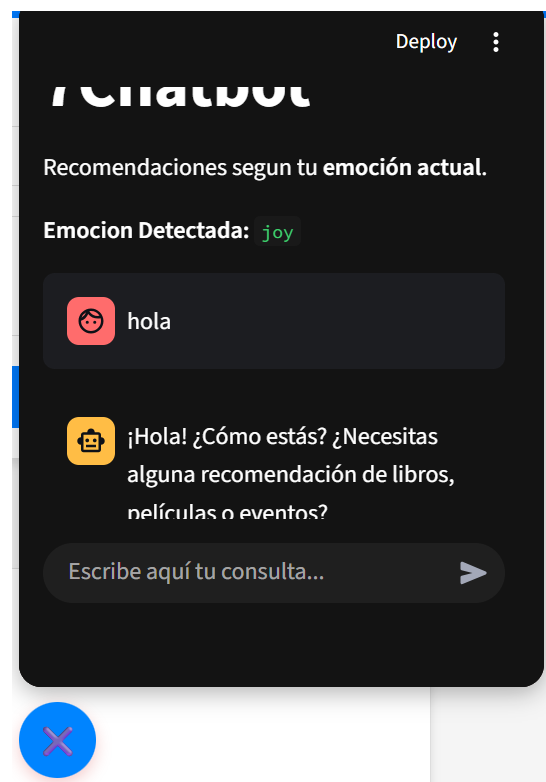
(c) Feed Principal

Fuente: Elaboración propia


Figura 11: Pantallas de Inicio, Registro y Feed




(a) Chat del chatbot
Fuente: Elaboración propia



(b) Ingreso de texto al chat
Fuente: Elaboración propia



(c) Petición de recomendación
Fuente: Elaboración propia



(d) Presentación de la recomendación
Fuente: Elaboración propia

Figura 12: Interacciones del chatbot

6.11. Consideraciones Éticas

En el desarrollo del sistema de recomendación y generación de contenido emocional para redes sociales, es fundamental garantizar el cumplimiento de las normativas éticas y legales relacionadas con la recopilación, almacenamiento, uso y procesamiento de datos personales. A continuación, se describen las principales consideraciones éticas, ajustadas a las leyes colombianas y basadas en principios de privacidad, transparencia y respeto a los derechos de los usuarios.

1. Cumplimiento de la Ley 1581 de 2012, también conocida como la Ley de Protección de Datos Personales en Colombia, establece el marco normativo para garantizar la protección de los derechos de los titulares de datos personales. En este sentido, el proyecto debe:

Solicitar el consentimiento previo, expreso e informado de los usuarios para recopilar y procesar sus datos. Garantizar que los datos sean utilizados únicamente para los fines previamente establecidos y comunicados al usuario. Asegurar el derecho de los titulares a acceder, actualizar, rectificar y eliminar sus datos en cualquier momento.

2. Minimización y Relevancia de los Datos: El sistema debe adherirse al principio de minimización de datos, recopilando únicamente la información estrictamente necesaria para el análisis emocional y la generación de contenido. Además, el procesamiento de datos debe evitar el uso de información sensible que pueda generar discriminación, como datos relacionados con religión, orientación sexual, creencias políticas, entre otros.

3. Transparencia y Finalidad: En conformidad con la Resolución 312 de 2020, emitida por la Superintendencia de Industria y Comercio (SIC), los usuarios deben ser informados de manera clara y accesible sobre:

Los objetivos específicos del procesamiento de sus datos. Los métodos utilizados para analizar emociones y generar contenido. Las medidas implementadas para proteger su información.

4. Confidencialidad y Seguridad: El sistema debe implementar mecanismos robustos de seguridad, siguiendo estándares internacionales como ISO/IEC 27001, para garantizar la confidencialidad, integridad y disponibilidad de los datos. Esto incluye:

Cifrado de datos sensibles durante la transmisión y almacenamiento. Implementación de controles de acceso para evitar el uso no autorizado de la información. Protocolos de respuesta ante incidentes para mitigar posibles brechas de seguridad.

5. Ética en el Uso de la Inteligencia Artificial Al utilizar algoritmos de procesamiento de lenguaje natural (NLP) y técnicas de computación afectiva, se debe:

Garantizar que los modelos no perpetúen sesgos discriminatorios. Asegurar que los resultados generados no promuevan contenidos dañinos, engañosos o que atenten contra la dignidad humana. Validar los modelos a través de pruebas controladas con usuarios, promoviendo la equidad en el diseño.

6. Derechos de los Usuarios y Participación Se debe habilitar un mecanismo para que los usuarios puedan ejercer sus derechos, tales como: retirar su consentimiento en cualquier momento.

Referencias: [17],[18].

7. Pruebas

7.1. Pruebas Funcionales y de validacion del chatbot

El desarrollo de un chatbot no se limita únicamente a la implementación de sus funcionalidades principales, sino que también requiere un proceso riguroso de pruebas que garantice su correcto desempeño en distintos escenarios de uso. Estas pruebas permiten validar que el sistema responda de manera adecuada a las entradas del usuario, que detecte correctamente el tipo de recomendación solicitada (libro, película o evento), que maneje los errores de forma controlada y que preserve la coherencia en la interacción a lo largo de la conversación.

Tabla de pruebas del Chatbot de Recomendaciones

Nº	Prueba	Entrada del usuario	Acción Esperada	Resultado Obtenido
1	Saludo natural	"Hola"	El bot responde con un saludo breve y natural, sin dar recomendaciones.	Responde: "¡Hola! ¿En qué puedo ayudarte hoy?"
2	Detección de intención (Libro)	Recomiéndame un libro	El bot detecta la intención → activa tipo = Libro y responde: ".Entendido, buscaré un Libro para ti."	Detecta la intención y muestra recomendación desde API Google Books.
3	Detección de intención (Película)	"Quiero ver una película"	El bot detecta la intención → activa tipo = Película y responde: ".Entendido, buscaré una Película para ti."	Detecta intención, llama API OMDb y devuelve título, poster y sinopsis.
4	Detección de intención (Evento)	"Quiero ver un evento"	El bot detecta la intención → activa tipo = Evento y responde: ".Entendido, buscaré un Evento para ti."	Detecta intención, llama API Ticketmaster y devuelve descripción, lugar, fecha y hora.

N°	Prueba	Entrada del usuario	Acción Esperada	Resultado Obtenido
5	Entrada fuera de contexto	"¿Qué clima hará mañana?"	El bot responde: "Lo siento, solo puedo recomendar libros, películas o eventos según tu emoción."	Muestra el mensaje correctamente sin alucinar.
6	Recuperación de emoción detectada	Usuario con emoción previa = joy, luego escribe recomiéndame algo"	El bot mantiene la emoción joy y recomienda acorde a ese estado.	La emoción se conserva en st.session_state y guía la recomendación.

Tabla 13: Pruebas del chatbot de recomendaciones.

Fuente: Elaboración propia.

7.2. Pruebas Unitarias del algoritmo de clasificación emocional

Para garantizar la correcta funcionalidad del algoritmo de clasificación emocional desarrollado con la librería pysentimiento, se realizaron pruebas unitarias haciendo uso del módulo estándar **Unittest** de python, estas pruebas permiten validar si el algoritmo de clasificación es capaz de identificar de manera precisa la emoción que predomina en diferentes entradas de texto como el texto solo, 2 textos y hasta 3 textos juntos.

A continuación, se presentan los resultados de la ejecución de las pruebas, los cuales muestran la emoción dominante y las probabilidades asociadas a cada categoría emocional para cada conjunto de publicaciones evaluado:

1. Test Unitario Emoción Positiva

Objetivo: Su objetivo es identificar una emoción positiva

Post "Me siento muy feliz con los resultados"

Emoción Predominante: joy

Probabilidades:

Others	Joy	Sadness	Anger	Surprise	Disgust	Fear
0.00169	0.99317	0.00079	0.00032	0.00229	0.00082	0.00091

Funciona de manera efectiva con un solo post

Test ok.

Tabla 14: Test unitario emoción positiva

Fuente: Elaboración propia.

2. Test Unitario Emoción Negativa

Objetivo: Su objetivo es identificar una emoción negativa

Post “Estoy cansado de todo, nada tiene sentido”

Emoción Predominante: Anger

Probabilidades:

Others	Joy	Sadness	Anger	Surprise	Disgust	Fear
0.06865	0.01020	0.09233	0.74914	0.00441	0.05406	0.02113

Funciona de manera efectiva con un solo post

Test ok.

Tabla 15: Test unitario emocion negativa

Fuente: Elaboración propia.

3. Test Unitario Entrada Vacía

Objetivo: Su objetivo es identificar qué reacción toma el algoritmo al identificar una entrada vacía

Post “ ”

Emoción Predominante: Others

Probabilidades:

Others	Joy	Sadness	Anger	Surprise	Disgust	Fear
0.23776	0.12080	0.21519	0.11919	0.14209	0.08629	0.07864

Funciona de manera efectiva con el post vacío por lo cual no presenta error, además representa el sentimiento como other's al no identificar una emoción

Test ok.

Tabla 16: Test unitario entrada vacia

Fuente: Elaboración propia.

4. Test Unitario Entrada Múltiple

Objetivo: Su objetivo es identificar cómo reacciona el algoritmo al analizar diferentes posts

Post “1. .Estoy feliz por terminar el proyecto” 2..Aunque también me siento algo estresado.””

Emoción Predominante: Joy

Probabilidades:

Others	Joy	Sadness	Anger	Surprise	Disgust	Fear
0.00678	0.98200	0.00503	0.00049	0.00229	0.00077	0.00168

Funciona de manera efectiva con el post de entrada multiple
Test ok.

Tabla 17: Test unitario entrada multiple

Fuente: Elaboración propia.

5.Test Unitario Entrada de simbolos

Objetivo: Su objetivo es identificar cómo reacciona el algoritmo al analizar un post que contiene símbolos

Post “@@@”

Emoción Predominante: Others

Probabilidades:

Others	Joy	Sadness	Anger	Surprise	Disgust	Fear
0.97725	0.00890	0.00296	0.00211	0.00713	0.00073	0.00083

Funciona de manera efectiva con el post de entrada conformada por símbolos
Test ok.

Tabla 18: Test unitario entrada de simbolos

Fuente: Elaboración propia.

6.Test Unitario Entrada de signos

Objetivo: Su objetivo es identificar cómo reacciona el algoritmo al analizar un post que contiene signos de interrogación

Post “???”

Emoción Predominante: Surprise

Probabilidades:

Others	Joy	Sadness	Anger	Surprise	Disgust	Fear
0.28574	0.10833	0.03948	0.01508	0.51569	0.01410	0.02159

Funciona de manera efectiva con el post de entrada conformado por signos de interrogación pero esta vez la emoción es sorpresa
Test ok.

Tabla 19: Test unitario entrada de signos

Fuente: Elaboración propia.

7. Test Unitario Entrada sin sentido

Objetivo: Su objetivo es identificar cómo reacciona el algoritmo al analizar un post que contiene una entrada sin sentido

Post “ewtgergrehbtehsdferg”

Emoción Predominante: Others

Probabilidades:

Others	Joy	Sadness	Anger	Surprise	Disgust	Fear
0.28574	0.10833	0.03948	0.01508	0.51569	0.01410	0.02159

Funciona de manera efectiva con el post de entrada sin sentido ,pues está respondiendo con la emoción other al no poder identificar claramente una emoción

Test ok. Ran 7 tests ok

Todos los tests pasaron de manera efectiva en un tiempo estimado de 0.749s

Tabla 20: Test unitario entrada sin sentido

Fuente: Elaboración propia.

7.3. Discusión de los Resultados

Las pruebas unitarias realizadas permitieron evaluar el desempeño del algoritmo de clasificación emocional basado en **PySentimiento** frente a distintos tipos de entradas. En general, los resultados muestran que el modelo cumple adecuadamente con la identificación de emociones predominantes y mantiene un comportamiento estable incluso ante textos ambiguos o sin contenido semántico claro.

Para entradas con emociones explícitas, como textos positivos o negativos, el modelo clasificó correctamente *joy* y *anger* como emociones dominantes, con probabilidades significativamente superiores al resto. Esto confirma que el algoritmo es preciso cuando la emoción es clara en el mensaje.

En escenarios mixtos, donde el texto combina múltiples emociones, el modelo seleccionó la emoción con mayor peso semántico, manteniendo coherencia con el enfoque de clasificación dominante propio de la librería. Esto refleja un funcionamiento adecuado en situaciones donde el usuario expresa más de una emoción.

En el caso de entradas atípicas —como texto vacío, símbolos o cadenas sin sentido— el modelo asignó emociones como *others* o *surprise*, demostrando robustez ante datos ruidosos y evitando fallos o excepciones durante su ejecución.

7.4. Impacto de la integración mediante pruebas de usuarios

7.5. Objetivo y planteamiento de las pruebas

La integración de sistemas o funcionalidades en un entorno de desarrollo no se considera completa hasta que sea validada por quienes realmente los utilizan, los usuarios finales. Las pruebas de usuarios en un entorno controlado representan una fase crítica dentro del ciclo de vida de software, ya que esta permite identificar fallos de usabilidad.

Las pruebas de usuario garantizan que el sistema cumpla con los requisitos funcionales, sino que también permite evaluar la experiencia de usuario al interactuar, medir la satisfacción y recoger retroalimentación directa. En este estudio se diseñaron 2 Pruebas 1 con Mastodon y la 2 con Red Social Propia 7social, consta la 1 prueba de 11 preguntas, de las cuales 10 son de opción múltiple y cerrada y 1 de respuesta abierta, y la 2 prueba consta de 10 preguntas, de las cuales 8 son de opción múltiple y 2 de respuesta abierta con el objetivo de medir el impacto de la integración de las funcionalidades, analizar su facilidad de uso y determinar el nivel de aceptación por parte de los participantes.

El análisis de estas respuestas permitirá validar si los cambios implementados cumplen con las expectativas, también para detectar posibles fricciones en el flujo de uso y proponer mejoras que incrementen la calidad y confiabilidad del sistema antes de su despliegue final

Objetivos

1.Experiencia de usuario (UX): Obtención de información de cómo los usuarios perciben la interfaz de usuario, Evaluar la intuitividad del flujo y las funciones dentro de la aplicación.

2.Validar decisiones de diseño: Obtencion de informacion sobre decisiones de diseño tomadas durante el desarrollo de la aplicación, se piedra traducir a una experiencia positiva para el usuario.

3.Facilidad en la usabilidad: Comprender con qué facilidad los usuarios comprenden y aprenden a usar la aplicación identificando posibles áreas de confusión o dificultad en diferentes procesos como: registro , inicio de sesión, y uso del chatbot.

4.Satisfacción del usuario: Obtener información sobre la satisfacción general del usuario con la aplicación. identificar aspectos que contribuyan positivamente o negativamente.

5.Áreas de Mejora Descubrir problemas o áreas de la aplicación que podrían necesitar mejoras o ajustes, recolección de sugerencias y comentarios de los usuarios sobre cómo mejorar la aplicación

7.6. Planificación de las pruebas

Se utilizó la escala de likert que es una técnica de medición ampliamente utilizada en investigaciones sociales, psicológicas, educativas y de usabilidad para evaluar actitudes, percepciones, opiniones o niveles de satisfacción de los participantes frente a una afirmación o ítem específico.

Fue desarrollada por Rensis Likert en 1932 y se basa en la idea de que las actitudes no son dicotómicas (sí/no), sino que pueden tener diferentes grados de intensidad.


Cada respuesta se asocia con un valor numérico, permitiendo cuantificar actitudes subjetivas.

Se realizaron las siguientes preguntas utilizando la escala de likert del 1 al 5 donde:

Escala De Likert:


- 1 = Totalmente en desacuerdo
- 2 = En desacuerdo
- 3 = Neutral
- 4 = De acuerdo
- 5 = Totalmente de acuerdo

Facilidad de uso e intuición



(a) Facilidad de uso e intuición

Diseño visual y velocidad de carga



(b) Diseño visual y velocidad

Figura 13: Evaluación de la experiencia del usuario en la plataforma

Efectividad del componente emocional

Efectividad del Componente Emocional en las Recomendaciones




Figura 14: Efectividad del análisis emocional en la coherencia de recomendaciones

Las preguntas y los diagramas de torta, debido a la extensión del trabajo, se encuentran disponibles en formato digital en el siguiente enlace:

<https://drive.google.com/file/d/1GUMLIgeCDOdOB-RBsKc67r2NciCU1YWr/view?usp=sharing>

7.7. Análisis de los resultados de las pruebas con Mastodon

1.Facilidad de uso e intuición: Las gráficas muestran que la mayoría de los participantes percibieron al chatbot como fácil de usar e intuitivo, aunque no fue la misma opinión en cuanto al uso de mastodon ya que algunos lo tildaban de ser un poco engorroso. Lo anterior confirma que el flujo de navegación es claro y que las funciones están bien organizadas para el usuario en el chatbot en cuanto a mastodon exigen una alternativa más flexible.

2.Diseño visual: Predominan las respuestas positivas en la torta de diseño, lo que indica que la interfaz fue visualmente agradable y contribuyó a una experiencia fluida.

3.Detección emocional: La mayoría de los encuestados coincidió en que el chatbot detectó correctamente sus emociones, lo que valida el componente de análisis emocional como un punto positivo de la integración sin embargo algunos optaron porque su emoción no era tan acertada debido a que las emociones pueden llegar a ser mucho más complejas y un nivel de dificultad más alto para detectarlas.

4.Recomendaciones: Las gráficas de relevancia y variedad muestran una tendencia favorable, reflejando que el contenido sugerido fue útil, interesante y ayudó a los usuarios a descubrir cosas nuevas.

5.Sensación de acompañamiento: Aunque la mayoría de respuestas fueron positivas, las tortas muestran una proporción menor en este ítem en comparación con los demás. Esto sugiere que se puede mejorar la empatía y la naturalidad de las respuestas para generar mayor conexión emocional, además de tener en cuenta de integrar posiblemente algunas instrucciones para mejorar la experiencia del usuario .

6.Satisfacción global: La gran mayoría expresó estar satisfecha con la experiencia completa, lo que valida la integración con Mastodon como funcional aunque un poco engorroso

Comentarios Adicionales:

Las respuestas abiertas destacaron que el chatbot es útil y funcional, pero señalaron áreas de mejora como: Ampliar la variedad de contenidos recomendados. Mejorar la precisión en la detección de emociones en algunos casos. Optimizar el flujo de interacción y agregar mensajes más claros para guiar al usuario. Estos comentarios constituyen una valiosa fuente de información para iterar sobre el diseño y refinar la experiencia del usuario

7.8. Análisis de los resultados de las pruebas con 7social

1.Facilidad de uso e intuición: Las tortas de esta encuesta muestran una aceptación muy alta, indicando que la plataforma fue percibida como simple y sin fricciones para navegar de manera fácil y sencilla.

2.Diseño visual y velocidad de carga: Las gráficas reflejan una valoración muy positiva, destacando que la interfaz resultó agradable y que el tiempo de respuesta fue rápido, contribuyendo a una experiencia más dinámica.

3.Funciones de la red social: Los ítems relacionados con publicar, editar y borrar publicaciones tienen mayoría de respuestas positivas, confirmando que estas acciones fueron claras y fáciles de realizar.

4.Detección emocional: La mayoría consideró que el chatbot identificó correctamente su estado emocional, permitiendo recomendaciones acordes.

5.Recomendaciones: Las tortas muestran que los usuarios consideraron relevantes las sugerencias y con variedad suficiente, aunque en los comentarios surgieron ideas para mejorar la personalización y ampliar la gama de contenidos.

6.Satisfacción global: La aceptación general fue muy alta, con gran disposición de los usuarios a recomendar el sistema a otras personas.

7.9. Aplicación y Justificación de la Prueba con Usuarios

Las pruebas con la plataforma **7social** se realizaron durante un periodo de dos días, en sesiones independientes donde cada participante interactuó libremente con el sistema. El proceso incluyó el registro, la navegación por la interfaz, la publicación de contenido, el uso del chatbot emocional y la recepción de recomendaciones. Al finalizar, se aplicó

una encuesta estructurada para validar aspectos de usabilidad, desempeño, detección emocional y satisfacción general. Este procedimiento permitió obtener una verificación completa del funcionamiento de la plataforma en condiciones reales de uso, la muestra estuvo compuesta por 80 estudiantes.

La muestra que estuvo compuesta por 5 egresados de la institución en las pruebas de nielsen. Aunque el tamaño es reducido, esta elección responde a criterios de **prueba piloto**, cuyo objetivo principal es identificar problemas tempranos antes de ampliar la validación a una población mayor. Los egresados seleccionados comparten características relevantes: experiencia previa con plataformas digitales, afinidad por el uso de redes sociales y disponibilidad para participar en procesos de retroalimentación detallada. Además, al no pertenecer directamente al desarrollo del proyecto, ofrecieron una perspectiva externa y objetiva sobre la funcionalidad del sistema.

7.10. Pruebas de usabilidad de nielsen

Las pruebas de Nielsen se basan en los 10 principios heurísticos de usabilidad propuestos por Jakob Nielsen, uno de los referentes en diseño centrado en el usuario.

Estas pruebas sirven para evaluar qué tan fácil, clara y coherente es una interfaz desde el punto de vista del usuario. En lugar de medir con datos técnicos, se centra en la percepción del usuario al interactuar con el sistema.

Para la implementación de la prueba se presentan 11 preguntas de las cuales 10 son cerradas y la última es abierta, se tuvieron en cuenta la opinión de 5 egresados profesionales, Además cabe destacar que para la calificación se utilizó de nuevo la escala de likert.

Los 10 principios de Nielsen (adaptados al chatbot emocional) son:

1. Visibilidad del estado del sistema

El chatbot debe indicar cuando está procesando un mensaje o buscando una recomendación (“Buscando recomendaciones...”).

2. Correspondencia entre el sistema y el mundo real

Los mensajes deben estar redactados en un lenguaje natural, empático y comprensible, evitando tecnicismos.

3. Control y libertad del usuario

El usuario debe poder volver atrás, corregir mensajes o solicitar nuevas recomendaciones sin confusión.

4. Consistencia y estándares

Los colores, íconos, fuentes y estilo del chatbot deben mantenerse iguales en toda la interfaz de Social.

5. Prevención de errores

El sistema debe evitar errores de detección o respuesta, y guiar al usuario cuando algo no se procesa correctamente.

6. Reconocimiento antes que recuerdo

Las opciones e instrucciones deben ser visibles y fáciles de identificar, sin necesidad de que el usuario recuerde comandos.

7. Flexibilidad y eficiencia de uso

El chatbot debe responder fluidamente tanto a usuarios nuevos como a frecuentes, sin demoras ni bloqueos.

8.Diseño estético y minimalista

El diseño debe ser visualmente limpio, atractivo y sin elementos innecesarios que distraigan al usuario.

9.Ayuda para reconocer, diagnosticar y corregir errores

Cuando ocurre un error, el chatbot debe mostrar un mensaje claro (“No puedo procesar tu solicitud, sólo puedo recomendar libros,películas,eventos”).

10.Ayuda y documentación

El sistema debe ofrecer mensajes o guías breves que orienten al usuario sobre cómo interactuar con el chatbot.

Las preguntas y los diagramas de torta debido a la extension del trabajo se encuentran disponibles en formato digital en el siguiente enlace:

<https://drive.google.com/file/d/1GUMLIgeCDOdOB-RBsKc67r2NciCU1YWr/view?usp=sharing>

7.11. Análisis de los resultados

1. Facilidad de uso e intuición: Los resultados muestran que la mayoría de los participantes percibió que la interacción con el chatbot es clara y fácil de entender, especialmente en cuanto a la rapidez de respuesta y la adaptación tanto para usuarios nuevos como frecuentes. Sin embargo, los ítems relacionados con modificar o volver atrás y la visibilidad de opciones recibieron puntuaciones más bajas, lo que indica que aún se puede mejorar la navegación y el control de las acciones del usuario.

2. Diseño visual y consistencia: Los ítems sobre diseño visual fueron valorados positivamente, reflejando que la interfaz del chatbot es agradable y coherente con la plataforma 7Social. Los usuarios destacaron la claridad en la presentación de los elementos y la ausencia de componentes innecesarios, lo que contribuye a una experiencia visual satisfactoria. No obstante, algunos comentarios sugieren aumentar el espacio entre los elementos y hacer la UI responsive para dispositivos móviles.

3. Manejo de errores y guía del usuario: El chatbot fue percibido como adecuado al manejar errores y ofrecer mensajes claros cuando ocurren, lo que reduce la frustración del usuario. Sin embargo, las puntuaciones más bajas se concentran en los ítems de orientación y guías de uso, evidenciando que los usuarios requieren instrucciones más visibles y apoyo adicional para comprender completamente cómo interactuar con el sistema.

4. Lenguaje y comunicación: El lenguaje utilizado por el chatbot fue considerado claro y natural por la mayoría de los participantes, facilitando la comprensión de sus respuestas y recomendaciones. Esto contribuye a que la experiencia sea más intuitiva y cercana al usuario.

5. Recomendaciones y personalización: Si bien los usuarios percibieron que el chatbot ofrece recomendaciones relevantes, los comentarios sugieren que la experiencia se podría optimizar mediante la implementación de guías de uso y la mejora en la personalización de las sugerencias, así como en la visibilidad de instrucciones para realizar acciones dentro de la plataforma.

6. Satisfacción global: En términos generales, la aceptación del chatbot fue alta, destacando su rapidez, adaptabilidad y diseño visual. Los usuarios mostraron disposición para continuar usando la herramienta, aunque también proporcionaron recomendaciones concretas para optimizar la facilidad de uso y la experiencia emocional dentro de 7Social.

8. Conclusiones Comparativas

8.1. Conclusiones

El desarrollo de este trabajo permitió cumplir con los objetivos propuestos, implementando un prototipo de sistema de recomendación basado en computación afectiva y procesamiento de lenguaje natural, integrado en un entorno social. A continuación, se presentan las principales conclusiones derivadas del proceso de diseño, implementación y evaluación del sistema.

8.1.1. 1. Experiencia de usuario e interacción

Los usuarios percibieron el chatbot como una herramienta fácil de usar, con una interfaz clara y fluida. En las pruebas realizadas en ambos entornos —Mastodon y 7Social— se observó una buena aceptación general; sin embargo, las gráficas y respuestas cualitativas evidenciaron una ligera preferencia por 7Social, donde los participantes manifestaron mayor comodidad y familiaridad. Este resultado demuestra que un entorno propio y adaptado al público objetivo favorece la participación y mejora la percepción de la experiencia.

8.1.2. 2. Caracterización de patrones emocionales

El uso de la librería *pysentimiento* permitió identificar y clasificar emociones en textos escritos por los usuarios, logrando una detección adecuada de emociones básicas como alegría, tristeza, ira y miedo. Aunque los resultados mostraron precisión aceptable, se evidenció que las emociones mixtas o sutiles presentan un mayor margen de error, lo que indica la necesidad de explorar modelos híbridos o de contexto ampliado para mejorar la comprensión emocional del sistema.

8.1.3. 3. Diseño e implementación del chatbot emocional

El chatbot cumplió su función principal de recolectar información textual y ofrecer interacción en lenguaje natural. Más del 70 por ciento de los encuestados consideró que la comunicación fue clara y sencilla, lo que valida el diseño conversacional adoptado. No obstante, las respuestas abiertas señalaron la necesidad de incrementar la empatía y

naturalidad en los mensajes, así como la posibilidad de incorporar guías contextuales o mensajes adaptativos según la emoción detectada. Estos aportes orientan futuras mejoras hacia un acompañamiento emocional más humano y personalizado.

8.1.4. 4. Integración del análisis emocional con las recomendaciones

La vinculación entre la detección de emociones y la generación de recomendaciones se implementó con éxito. Los usuarios valoraron positivamente la coherencia entre su estado emocional y los contenidos sugeridos, aunque también solicitaron mayor variedad de opciones. Estos resultados confirman que el enfoque funciona adecuadamente, pero puede fortalecerse al incorporar nuevas fuentes de datos, categorías y modelos más sofisticados para refinar la precisión de las sugerencias.

8.1.5. 5. Evaluación comparativa en redes sociales

La integración del sistema en Mastodon y en la red propia 7Social permitió validar su desempeño en distintos entornos. Mastodon sirvió como base técnica funcional, mientras que 7Social ofreció un flujo más optimizado, mayor control de datos y mejor adaptación a los usuarios. Los resultados cuantitativos y cualitativos coincidieron en que 7Social proporcionó una experiencia superior, consolidándose como la plataforma idónea para el despliegue final del chatbot emocional.

8.1.6. 6. Satisfacción general y proyección futura

Más del 75 por ciento de los usuarios expresó satisfacción con la detección emocional y las recomendaciones generadas. Sin embargo, también se identificaron áreas de mejora, como el fortalecimiento del componente empático y la diversificación de contenidos. En conjunto, el sistema demostró ser funcional, viable y bien recibido, validando la efectividad de combinar procesamiento de lenguaje natural, análisis emocional y motores de recomendación dentro de una red social.

8.1.7. 7. Enfoque técnico

El desarrollo del sistema permitió identificar tanto beneficios como limitaciones relacionadas con la selección de algoritmos y herramientas utilizadas:

Ventajas:

- *Lenguaje de programación:* Python facilitó la integración de librerías de procesamiento de lenguaje natural y análisis emocional (*pysentimiento*, *spaCy*), gracias a su sintaxis clara y amplio ecosistema de paquetes científicos, así como la implementación de la interfaz del chatbot streamlite potenciando el uso del chatbot como herramienta esencial en la interacción con el usuario.
- *Algoritmos de recomendación:* La implementación de filtrado colaborativo basado en usuarios e ítems, así como el uso del algoritmo Slope One, permitió generar sugerencias coherentes con las emociones detectadas, además estos algoritmos ayudan

a amortiguar el empezado en frio o problema de cold start ya que el algoritmo comienza a funcionar con pocos datos y se va alimentando de los usuarios con sus calificaciones relacionando su estado emocional con los contenidos del sistema, en comparacion con algoritmos mas avanzados que requieren un volumen grande de datos para funcionar.

- *Preprocesamiento de datos:* El uso de tokenización, lematización y limpieza de texto mejoró la calidad de los datos de entrada, incrementando la precisión de la detección emocional
- *Entrenamiento y validación:* Los procesos de entrenamiento y ajuste de parámetros fueron eficientes gracias a librerías optimizadas (estas ya cuentan con un entrenamiento de modelos como Large Encore News indicando un modelo large tipo transformer el cual esta entrenado en base a publicaciones reales de noticias en las redes sociales, en cuanto a la usabilidad en el sistema propio se realizaron pruebas con mastodon trayendo atravez de la api un dataset de publicaciones y generando recomendaciones entrenando los modelos de recomendacion junto con las pruebas realizadas en 80 estudiantes y 5 egresados de la universidad del valle).

Desventajas:

- *Lenguaje de programación:* Aunque Python es flexible, presenta limitaciones en rendimiento para procesamiento masivo en tiempo real, lo que podría ser un factor a considerar en escalabilidad futura.
- *Algoritmos de recomendación:* Los modelos basados en filtrado colaborativo requieren un número mínimo de calificaciones para ofrecer recomendaciones precisas, lo que puede limitar su efectividad en fases iniciales con pocos usuarios o datos.
- *Preprocesamiento de datos:* La limpieza y normalización de textos no siempre capturan sutilezas del lenguaje, como sarcasmo, ironía o emociones mixtas, lo que puede afectar la detección emocional, ya que no todos los textos poseen en si una emocion relacionada
- *Entrenamiento y ajuste:* La selección de hiperparámetros y validación cruzada consume tiempo y requiere supervisión, lo que podría dificultar actualizaciones frecuentes del sistema.

9. Trabajos Futuros

A partir de los hallazgos y observaciones de los usuarios, se proponen los siguientes trabajos que son mejoras que se pueden aplicar y desarrollar en un tiempo futuro:

1. Mejorar la empatía del chatbot mediante respuestas más naturales, contextuales y cercanas al lenguaje humano.
2. Ampliar la diversidad de recomendaciones, integrando nuevas APIs (música, noticias, juegos) que aumenten la variedad de contenidos sugeridos.
3. Consolidar y escalar 7Social, garantizando mayor estabilidad, seguridad y adopción de usuarios.
4. Realizar pruebas a mayor escala y en entornos reales, para evaluar métricas de efectividad, satisfacción y retención de usuarios.
5. Profundizar en el análisis cualitativo, aplicando minería de texto a las respuestas abiertas para identificar patrones más detallados de percepción.
6. Explorar recomendaciones multimodales, combinando texto con otras entradas como voz, imágenes o expresiones faciales para enriquecer la personalización.
7. Explorar e implementar otros tipos de recomendadores para observar la variabilidad de las recomendaciones ofrecidas a los usuarios desde distintos algoritmos

10. Bibliografía

Referencias

- [1] R. W. Picard, *Affective Computing*. Cambridge, MA: MIT Press, 1997.
- [2] G. Schuller, M. Valstar, and A. Eyben, "The INTERSPEECH 2013 computational paralinguistics challenge: Social signals, affect and inclusion," in *Proc. INTERSPEECH*, 2013, pp. 965-969.
- [3] S. Kern, M. Elkins, and K. G. Schulz, "Emotion recognition in texts for personalized recommendations," *Journal of Personalization Technology*, vol. 10, no. 4, pp. 201-215, 2015.
- [4] X. Liu, L. Xie, and F. Zhao, "Challenges in integrating affective computing with social media," *IEEE Transactions on Affective Computing*, vol. 9, no. 2, pp. 198-208, Apr.-June 2018.
- [5] P. Ricci, L. Rokach, and B. Shapira, *Recommender Systems Handbook*. Springer, 2011.
- [6] G. Adomavicius and A. Tuzhilin, "Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions," *IEEE Transactions on Knowledge and Data Engineering*, vol. 17, no. 6, pp. 734-749, 2005.
- [7] D. A. Norman, *The Design of Everyday Things*. Basic Books, 2002.
- [8] B. Liu, *Sentiment analysis and opinion mining*. Morgan & Claypool Publishers, 2012.
- [9] E. L. Deci and R. M. Ryan, "The 'What' and 'Why' of Goal Pursuits: Human Needs and the Self-Determination of Behavior," *Psychological Inquiry*, vol. 11, no. 4, pp. 227-268, 2000.
- [10] P. Rosales, J. Salas, and O. Tinoco, "Criterios de selección de metodologías de desarrollo de Software," *Revista de la Facultad de Ingeniería Industrial*, vol. 13, no. 1, pp. 70-74, 2010.
- [11] J. B. McGowan, "What is Scrumban? A Guide to the Hybrid Agile Methodology," Agile Alliance, 2020. [En línea]. Disponible en: <https://www.agilealliance.org/glossary/scrumban/>.
- [12] Andesco, "Resumen Ejecutivo de los 17 Objetivos de Desarrollo Sostenible," vol. 4, no. 1, pp. 64-75, 2016.
- [13] W. Kean-Fong et al., "Protocolo Global Para Inventarios de Emisión de Gases de Efecto Invernadero a Escala Comunitaria," Word Resources Institute, 2012.
- [14] UPME, "FACTOR DE EMISIÓN DEL SISTEMA INTERCONECTADO NACIONAL S.I.N.," 2019.
- [15] P. Ekman, *El rostro de las emociones*. Barcelona: RBA Libros, 2010.

- [16] C. D. Manning, H. Schütze, y P. Raghavan, Introduction to Information Retrieval. Cambridge: Cambridge University Press, 2008.
- [17] Congreso de la República de Colombia, Ley 1581 de 2012: Por la cual se dictan disposiciones generales para la protección de datos personales, Bogotá, Colombia, 2012.
- [18] Superintendencia de Industria y Comercio, Resolución 312 de 2020: Reglas para el tratamiento de datos personales, Bogotá, Colombia, 2020.
- [19] S. K. Bharti, S. Varadhaganapathy, R. K. Gupta, P. K. Shukla, M. Bouye, S. K. Hingaa, and A. Mahmoud, "Text-Based Emotion Recognition Using Deep Learning Approach, IEEE, 2022.
- [20] M. Karna, D. S. Juliet, and R. Joy, "Deep learning based text emotion recognition for chatbot applications," in 2020 4th International Conference on Trends in Electronics and Informatics (ICOEI)(48184), pp. 988-993, 2020.
- [21] Shaheen, S., El-Hajj, W., Hajj, H., Elbassuoni, S. (2014). Emotion recognition from text based on automatically generated rules. 2014 IEEE International Conference on Data Mining Workshop (ICDMW), 383-392.
- [22] Garima Gupta,Rahul Katarya.(2021)..^A Study of Deep Reinforcement Learning Based Recommender Systems,"2nd International Conference on Secure Cyber Computing and Communications (ICSCCC), 2021, pp. 978-1-6654-4415-6
- [23] A. H. Parizi y M. Kazemifard, ".Emotional News Recommender System,"2015 Sixth International Conference of Cognitive Science (ICCS), Teherán, Irán, 2015, pp. 37-41
- [24] M. K. Ranjan, M. Thakur, A. Sharma y N. Dhanda, "Music Recommendation System Using Python,"2024 4th International Conference on Technological Advancements in Computational Sciences (ICTACS), 2024, pp. 815-820
- [25] A. Barraza-Urbina y A. C. Ramos, "Vizier: un sistema de recomendación genérico y multidimensional,Revista Avances en Sistemas e Informática, vol. 8, no. 3, pp. 139-149, 2011
- [26] S. Cleger Tamayo, "Diseño y validación de modelos para Sistemas de Recomendación,"Tesis doctoral, Departamento de Ciencias de la Computación e Inteligencia Artificial, Universidad de Granada, Granada, España, 2013
- [27] T. Xiu, Y. Sun, X. Zhang, Y. Gao, J. Wu, A. Y. Zhang y H. Li, "The Analysis of Emotion-Aware Personalized Recommendations via Multimodal Data Fusion in the Field of Art," Journal of Organizational and End User Computing (JOEUC), vol. 37, no. 1, pp. 1-29, 2025.
- [28] K. K and S. T, ".Enhanced Product Recommendations based on Seasonality and Demography in Ecommerce,"2020 2nd International Conference on Advances in Computing, Communication Control and Networking (ICACCCN), Greater Noida, India, 2020, pp. 721-723

- [29] S. Song and K. Wu, .^A creative personalized recommendation algorithm—User-based Slope One algorithm,”2012 International Conference on Systems and Informatics (ICSAI2012), Yantai, China, 2012, pp. 2203-2207
- [30] RIVEROS BALBI, Norman. “Implementación de un sistema de recomendación de frases basado en el algoritmo Slope One”. 2013. Tesis Doctoral.
- [31] J. A. Rocha Hernández, D. M. Rodríguez Herrera, y J. E. Rodríguez Rodríguez, “A research comparative among association rules algorithms”, *Vis. Electron.*, vol. 10, n.^o 2, pp. 210–217, dic. 2016.
- [32] Jiawei Han, Jian Pei, and Yiwen Yin. 2000. “Mining frequent patterns without candidate generation”. In *Proceedings of the 2000 ACM SIGMOD international conference on Management of data (SIGMOD '00)*. Association for Computing Machinery, New York, NY, USA, 1–12.
- [33] M. J. Zaki, ”Scalable Algorithms for Association Mining,IEEE Transactions on Knowledge and Data Engineering, vol. 12, no. 3, pp. 372-390, May/Jun. 2000
- [34] Vibha and A. P. Singh, .^Aanalysis of Variants of KNN Algorithm based on Preprocessing Techniques,”2018 International Conference on Advances in Computing, Communication Control and Networking (ICACCCN), Greater Noida, India, 2018, pp. 186-191
- [35] S. Sen, M. N. Das and R. Chatterjee, .^A Weighted kNN approach to estimate missing values,”2016 3rd International Conference on Signal Processing and Integrated Networks (SPIN), Noida, India, 2016, pp. 210-214
- [36] J. M. Keller, M. R. Gray and J. A. Givens, .^A fuzzy K-nearest neighbor algorithm,in *IEEE Transactions on Systems, Man, and Cybernetics*, vol. SMC-15, no. 4, pp. 580-585, July-Aug. 1985
- [37] González, C. J. G., García, M. N. M., Gil, A. B., ”Sistema de Recomendación de Música Sensible al Contexto .^Aavances en Informática y Automática, vol. 65, 2020,pp.50
- [38] C. J. G. Lagos Urbina, Üso de técnicas de minería de opinión para apoyar la generación de recomendaciones de productos a partir de reseñas en idioma español,”Proyecto de Título para optar al grado de Ingeniero Civil en Informática, Universidad del Bío-Bío, Concepción, Chile, 2018.
- [39] F. Liu, Q. Cao, X. Huang, and H. Liu, ”Sentimentally enhanced conversation recommender system,Çomplex Intelligent Systems, vol. 11, no. 135, pp. 1-18, Jan. 2025.
- [40] Y. Qian, Y. Zhang, X. Ma, H. Yu, y L. Peng, .^{EA}RS: Emotion-aware recommender system based on hybrid information fusion”, *Information Fusion*, vol. 46, pp. 141–146, 2019.
- [41] J. Mizgajski and M. Morzy, .^Affective recommender systems in online news industry: How emotions influence reading choices,Üser Modeling and User-Adapted Interaction, vol. 29, no. 3, pp. 345–379, 2019.

- [42] P. A. Rodríguez Marín, Á. M. Pérez Zapata, L. F. Londoño Rojas, and N. D. Duque Mendez, "Sistema de recomendación de objetos de aprendizaje a través de filtrado colaborativo," *TEKNOS*, vol. 16, no. 2, pp. 85–94, 2016.
- [43] J. C. Carrillo Moraga, "Sistemas de recomendación de música para grupos," Trabajo Fin de Grado, Escola Tècnica Superior d'Enginyeria Informàtica, Universitat Politècnica de València, 2021.
- [44] G. Fayjie, A. El Saddik, and C. D. Nugent, ".Affective Computing for Social Companion Robots Using Fine-grained Speech Emotion Recognition,in *2023 IEEE Conference on Artificial Intelligence (CAI)*, 2023, pp. 331–336. doi: 10.1109/CAI54212.2023.00146.
- [45] M. Pudane, ".Affective Multi-Agent System: Modelling and Simulation of Social and Rational Effects of Emotions,in 2023 64th International Scientific Conference on Information Technology and Management Science (ITMS), 2023, pp. 1–7. doi: 10.1109/ITMS59786.2023.10317739.
- [46] Y. He, X. Wang, and M. Li, ".A Survey on Graph Neural Networks Method under Social Recommendation,in 2023 9th Annual International Conference on Network and Information Systems for Computers (ICNISC), 2023, pp. 583–587. doi: 10.1109/ICNISC60562.2023.00036.
- [47] O. ÖzBey and F. Kılıç, ".Experimental Investigation of Artificial Intelligence Models for Recommender Systems,in *2025 7th International Congress on Human-Computer Interaction, Optimization and Robotic Applications (ICHORA)*, 2025, pp. 1–9. doi: 10.1109/ICHORA65333.2025.11016991.

11. Anexos

Debido a su extensión, los anexos de este trabajo se encuentran disponibles en formato digital en el siguiente enlace:

<https://drive.google.com/file/d/1GUMLIgeCDOdOB-RBsKc67r2NciCU1YWr/view?usp=sharing>