Análisis de sentimientos Bancolombia

Paula Ximena Pérez García, Karen Milena Rodríguez Díaz, Ernesto Mendieta Sabogal

Universidad Santo Tomás
Bogotá, Colombia

Resumen

El análisis de sentimientos se ha convertido en una herramienta clave dentro de la minería de datos y el procesamiento de lenguaje natural (NLP), permitiendo evaluar las opiniones y emociones que los usuarios expresan en medios digitales. En el sector financiero, este tipo de análisis cobra especial relevancia por el impacto que tiene la percepción de los clientes en la reputación y posicionamiento de las entidades bancarias.

Este artículo presenta un estudio de análisis de sentimientos aplicado a comentarios publicados por usuarios en redes sociales, específicamente relacionados con la nueva aplicación móvil desarrollada por Bancolombia. A través de técnicas de aprendizaje automático y herramientas de análisis textual, se busca clasificar las opiniones en categorías de sentimiento y extraer patrones que permitan mejorar la experiencia del usuario. Los resultados obtenidos ofrecen una visión detallada de la percepción de los clientes y constituyen un insumo clave para la toma de decisiones en procesos de atención, diseño y comunicación digital.

Palabras clave: análisis de sentimientos Bancolombia; aprendizaje automático; percepción del cliente

Abstract

Sentiment analysis has become a key tool in data mining and natural language processing (NLP), allowing the evaluation of opinions and emotions expressed by users on digital platforms. In the financial sector, this type of analysis is especially relevant due to the strong influence that customer perception has on the reputation and positioning of banking institutions.

This article presents a sentiment analysis study applied to user comments posted on social media, specifically regarding the new mobile application launched by Bancolombia. Using machine learning techniques and textual analysis tools, the comments were classified into sentiment

DOI: https://doi.org/10.26507/paper.4521

categories to identify patterns and trends in user perception. The results offer a detailed view of customer experiences and serve as a valuable resource for improving user interface design, customer service strategies, and digital communication practices.

***Keywords**: Bancolombia sentiment analysis; machine learning; customer perception*

1. Introducción

En la era digital, las redes sociales y otras plataformas virtuales se han transformado en escenarios fundamentales para la interacción entre los consumidores y las organizaciones. Esta evolución ha modificado profundamente la forma en que las empresas entienden y gestionan la percepción del cliente. En este nuevo entorno, donde las experiencias de los usuarios se comparten pública y masivamente, el análisis de estas opiniones se ha convertido en una necesidad estratégica para muchas industrias, especialmente el sector financiero. (Plazas, Mejía y Montoya,2021)

Bancolombia, fundado en 1875 (Bancolombia, 2024), es una de las instituciones financieras más representativas de Colombia y América Latina. En su proceso de transformación digital, ha invertido significativamente en el desarrollo de canales virtuales y aplicaciones móviles para mejorar la experiencia del cliente. Sin embargo, esta digitalización también expone a la entidad a una evaluación constante por parte de los usuarios, cuyas opiniones pueden fortalecer o debilitar su reputación.

El análisis de sentimientos es una rama de la minería de texto que forma parte del procesamiento de lenguaje natural (NLP, por sus siglas en inglés), cuyo objetivo es identificar y clasificar opiniones expresadas en lenguaje humano en categorías como positivo, negativo o neutro (Liu, 2012). Este tipo de análisis, alimentado por técnicas de aprendizaje automático y modelos estadísticos, permite a las empresas comprender el tono emocional de los comentarios de los usuarios y tomar decisiones informadas (Liu, 2012).

En este contexto, la ingeniería de datos se vuelve un componente clave, ya que habilita la recolección, procesamiento y análisis estructurado de grandes volúmenes de información textual proveniente de diversas fuentes digitales. El uso combinado de algoritmos de clasificación, técnicas de vectorización y matrices de confusión posibilita evaluar el rendimiento de los modelos predictivos aplicados a los sentimientos expresados por los usuarios (Aggarwal, 2015).

Ejemplos de aplicación de estas herramientas en el entorno empresarial incluyen el monitoreo de reseñas de productos en Amazon, análisis de retroalimentación de clientes en servicios de atención como los de Claro o Movistar, y la evaluación de campañas de mercadeo en tiempo real por empresas como Netflix o Spotify. En el sector financiero, su utilidad ha sido ampliamente reconocida para mejorar la calidad del servicio, optimizar los procesos de atención al cliente y reforzar las estrategias de fidelización (Rodríguez & Camargo, 2020).

Este artículo presenta un análisis de sentimientos aplicado a los comentarios de clientes de Bancolombia sobre su nueva aplicación móvil, con el objetivo de identificar patrones de percepción

mediante técnicas de procesamiento de lenguaje natural y modelos de clasificación basados en aprendizaje automático. La información extraída busca aportar a la comprensión de la experiencia del usuario y facilitar el diseño de estrategias de mejora alineadas con sus expectativas.

2. Metodología

Para el desarrollo de este análisis de sentimientos se recopilaron comentarios en los meses de marzo y abril de los usuarios de Bancolombia relacionados con su nueva aplicación móvil. Estos comentarios fueron extraídos de las redes sociales y otros canales digitales donde los clientes manifestaron sus opiniones sobre su experiencia de uso.

El dataset utilizado contiene un total de 210 comentarios, los cuales fueron clasificados manualmente en tres categorías de sentimientos: Comentarios Negativos (-1), Comentarios Neutros (0) y Comentarios Positivos (1).

El análisis de sentimientos de los comentarios realizados hacia la empresa Bancolombia se llevó a cabo utilizando la plataforma Google Colab, un entorno de programación en la nube que permite desarrollar proyectos en Python de forma eficiente y colaborativa. A partir de una base de datos realizada en Excel que contenía comentarios explicado anteriormente, se desarrolló un proceso de análisis estructurado con base en un algoritmo construido desde cero. Además, se realizó un análisis exploratorio de los comentarios, identificando las palabras más frecuentes asociadas a los sentimientos expresados por los usuarios.

Para realizar el análisis de sentimientos se utilizó una evaluación mediante la matriz de confusión en este caso en específico multinomial que nos permite una comprensión más completa y precisa de las emociones expresadas con solo texto no ayuda a tener una visión más amplia de las emociones de los usuarios identificando así por medio del análisis de sentimientos esto para validar el rendimiento del modelo, comparando el análisis que hace el modelo, con la predicción que hace el modelo de machine learning entrenado, se empleó una matriz de confusión, que permite visualizar el desempeño del clasificador, mostrando la relación entre las etiquetas reales y las predichas e incluso es una herramienta útil para valorar como de bueno es el modelo de clasificación basado en un aprendizaje automático.

El análisis posee un enfoque mixto, ya que combina métodos cuantitativos con elementos estadísticos y de procesamiento de lenguaje natural. Por un lado, se utilizan técnicas cuantitativas como el uso de algoritmos de clasificación, la generación de matrices de confusión y el cálculo de métricas como precisión, estas herramientas permiten medir el rendimiento del modelo y obtener resultados numéricos objetivos. Por otro lado, el análisis también incorpora una interpretación cualitativa de los resultados, especialmente al evaluar los sentimientos expresados en los textos, clasificándolos en categorías como positivo, negativo o neutral. Esta combinación de enfoques permite una comprensión más profunda del modelo estudiado, no solo desde los datos y las cifras, sino también desde el significado e implicaciones del lenguaje utilizado por los usuarios.

3. Resultados

La recolección de datos se realizó el día 10 de abril del 2025; se tuvo en cuenta comentarios máximo con 2 semanas de publicación. Posteriormente se califican manualmente estos comentarios según su sentimiento así: 163 Negativos, 3 Neutros y 44 Positivos. Como se observa, la mayoría de los comentarios presentan una percepción negativa frente a la nueva aplicación de Bancolombia, lo cual representa un aspecto crítico para la entidad en términos de experiencia de usuario y reputación digital.

En el análisis se entrenó un modelo de clasificación de sentimientos utilizando técnicas de procesamiento de lenguaje natural, para ello, los textos fueron tokenizados y luego vectorizados utilizando la técnica TF-IDF (Term Frequency - Inverse Document Frequency), con el fin de transformar el lenguaje natural en una representación numérica que pudiera ser comprendida por modelos de machine learning. Se entrenaron modelos supervisados, principalmente Naive Bayes, para clasificar los comentarios según su polaridad. El conjunto de datos fue dividido en datos de entrenamiento y prueba, y se evaluó el desempeño del modelo utilizando matrices de confusión. Como resultados preliminares se obtuvo lo siguiente:

La siguiente grafica se obtuvo por medio de un entrenamiento del modelo multinomial en lenguaje natural (NLP) donde vectorizamos el texto que entrena el modelo y así la herramienta que utilizamos realiza la extracción de los coeficiente que se pueden visualizar en la gráfica estos coeficientes nos indican la importancia de cada palabra para una clase en particular y así interpretar el modelo identificando que palabras están más asociadas a sentimientos positivos, negativos o neutros, las palabras con coeficientes más altos son las que más peso tienen al momento de clasificar un texto en una categoría específica. Al graficar la distribución de estos coeficientes, se puede ver si el modelo depende fuertemente de pocas palabras o si la influencia está más distribuida.

Figura 1. Distribución de coeficientes del modelo

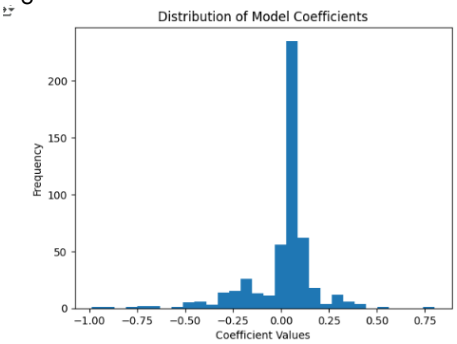

Fuente propia: Elaboración propia con Google Colab

Con base a la anterior grafica se presenta una alta concentración cerca del cero lo que implica que muchas palabras tienen una influencia baja en la clasificación, la presencia de pocos coeficientes en los extremos que son los valores que están más alejados de cero tanto en sentido positivo como negativo, lo que sugiere que hay palabras con una alta capacidad negativa. La distribución sugiere una especie de curva tipo campana centrada en 0, lo cual es común en modelos bien ajustados indicándonos en este caso que no están sesgados hacia una clase por ende esta

grafica nos demuestra que refuerza la idea de que el lenguaje usado por los usuarios tiene ciertos términos “marcados” muy claros para el análisis de sentimientos.

Basándonos en las anteriores graficas podemos interpretar el modelo desde la estadística, pero en las siguientes tablas interpretaremos el modelo desde el contenido.

Figura 2. Nubes de palabras

a) Palabras más positivas b) Palabras más negativas
Fuente propia: Elaboración propia con Google Colab

Figura 3. Palabras más positivas y negativas

Palabras más positivas:

	word	coefficient
313	muy	-0.986645
493	ya	-0.894619
34	buena	-0.795375
175	excelente	-0.703399
265	listo	-0.697879
289	me	-0.653032
35	bueno	-0.633468
427	realicé	-0.537027
452	super	-0.486025
285	maravilla	-0.483846

Palabras mas negativas:

	word	coefficient
330	no	0.800488
411	que	0.542452
447	sirve	0.440015
28	bancolombia	0.433640
471	un	0.408180
277	mal	0.404078
429	regular	0.383445
438	se	0.382736
361	peor	0.347807
27	banco	0.344618

Fuente propia: Elaboración propia con Google Colab

Estas imágenes muestran al principio dos nubes de palabras o más conocidas como *Word clouds* generadas a partir de los comentarios de usuarios donde nos permiten visualizar cuales son los términos más utilizados por los usuarios al expresar sus opiniones en este caso observamos que la nube de la izquierda representa comentarios positivos y la nube de la derecha comentarios negativos.

En tanto los comentarios positivos En esta nube predominan palabras como **"muy"**, **"buena"**, **"excelente"**, **"fácil"**, **"super"**, **"nueva"**, **"funciona"** y **"dinámica"**. Estas expresiones están fuertemente asociadas a experiencias satisfactorias con la aplicación o servicios del banco. También destaca la palabra **"app"**, lo cual indica que gran parte de los comentarios se relacionan con la aplicación móvil de Bancolombia, y los usuarios reconocen mejoras sean buenas o malas. Palabras como **"cambio"**, **"funciona"** y **"nueva"** sugieren aceptación y valoración de actualizaciones o renovaciones recientes en la app. La palabra **"dinámica"**, se encuentra asociada a una experiencia fluida o moderna, también refuerza la percepción positiva del sistema.

En contraste, la nube de la derecha muestra palabras como **"antes"**, **"clave"**, **"permite"**, **"borrepasó"**, **"explicaciones"**, **"problemas"** y expresiones informales como **"jajaja"**, que podrían reflejar frustración o sarcasmo. La repetición de la palabra **"clave"** y su aparición en contexto negativo podría indicar que los usuarios enfrentan dificultades con la generación, recuperación o uso de claves de acceso en la aplicación. También aparece frecuentemente **"app"**, lo que indica que, si bien muchos usuarios valoran positivamente la aplicación, también es un punto crítico donde se concentran quejas o problemas.

Las tablas de la figura 3 muestran los coeficientes obtenidos a partir del modelo de clasificación, exactamente las primeras 10 que arroja el lenguaje natural (NLP), el **coeficiente** indica qué tanto influye una palabra para determinar si un comentario es positivo o negativo. Valores negativos están asociados a **sentimientos positivos**, y valores positivos a **sentimientos negativos**. En la lista de palabras con mayor coeficiente positivo (asociadas al sentimiento negativo), encontramos expresiones de **negación o desaprobación** como **"no"**, **"mal"**, **"peor"**, y **"regular"**. Estas son claras indicadoras de insatisfacción. Es relevante que aparezcan palabras como **"sirve"** (probablemente en frases como "no sirve"), y que el propio nombre de la entidad, **"Bancolombia"**, tenga carga negativa, lo que puede indicar que el banco es directamente responsabilizado por la mala experiencia del usuario.

Además, la inclusión de palabras neutras como **"que"**, **"un"**, **"se"**, o **"banco"**, que en sí no expresan emociones, puede estar relacionada con su uso frecuente en estructuras negativas ("que mal", "un desastre", etc.), lo que indica patrones de lenguaje característicos en comentarios mayormente negativos. La matriz de confusión nos ayuda a evaluar el rendimiento del modelo de clasificación comparando las etiquetas verdaderas (lo que realmente era el comentario: positivo, neutro o negativo) con las etiquetas predichas por el modelo.

Esta matriz de confusión busca evaluar el rendimiento del modelo de clasificación de sentimientos con respecto a tres clases posibles: -1: Sentimiento negativo, 0: Sentimiento neutro, 1: Sentimiento positivo. El objetivo es ver cuántas veces el modelo acertó o se equivocó en la predicción de cada clase, comparado con la verdad real de los datos.

Figura 4. Matriz de confusión 1

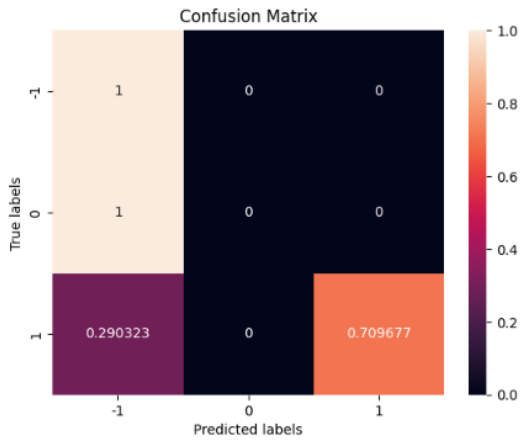

Fuente propia: Elaboración propia con Google Colab

- **Eje Y (vertical)**: Clases **reales** (las etiquetas verdaderas del dataset).
- **Eje X (horizontal)**: Clases **predichas** (lo que el modelo predijo).

- **Clase -1 (Negativa)**: En esta clase el modelo acierta completamente con los comentarios negativos: 100% de precisión.
- **Clase 0 (Neutra)**: El modelo no acierta ninguno: todos los comentarios neutros se clasifican erróneamente como negativos.
- **Clase 1 (Positiva)**: El modelo identifica correctamente el 71% de los comentarios acertados y el 29% restante los clasifica como negativos tiene una fuerte tendencia a clasificar todo como negativo. Aunque acierta con los negativos y la mayoría de positivos, ignora completamente los neutros, el modelo sí es capaz de detectar sentimientos positivos y negativos, también vemos un ligero sesgo hacia la clase negativa, ya que clasifica incorrectamente algunos positivos como negativos por lo tanto el modelo es bueno identificando comentarios negativos (100% de acierto) y aceptable para positivos (70.9% de acierto).

En la siguiente matriz de confusión

Figura 5. Matriz de confusión 2

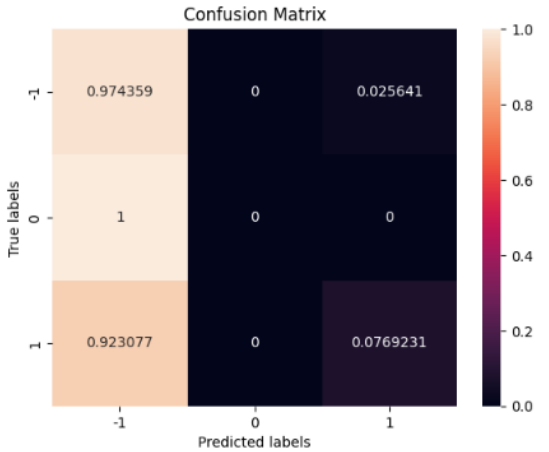

Fuente propia: Elaboración propia con Google Colab

- **Clase -1 (Negativa)**:

Esta clase se predicen correctamente en el 97% de los casos del modelo y un pequeño 2.5% se clasifica erróneamente como positivo.

- **Clase 0 (Neutra)**:

Todos los neutros son clasificados como negativos (100% error en esta clase).

- **Clase 1 (Positiva)**:

Solo 7.7% se clasifican correctamente y el 92% se consideran negativos.

Esta matriz revela lo que el modelo ha aprendido y cómo está funcionando y lo que vemos claramente es que el modelo aprendió a detectar bien los comentarios negativos ya que son los que más predominan por los usuarios en ella se observa que el modelo presenta un alto nivel de acierto en la identificación de comentarios negativos, con un 97.4% de precisión para esta clase.

Sin embargo, los comentarios neutros y positivos son clasificados erróneamente en su mayoría como negativos, lo que evidencia un claro sesgo del modelo hacia esta categoría.

La siguiente grafica muestra la frecuencia con la que diferentes emociones fueron detectadas en los comentarios analizados sobre Bancolombia con base en el modelo multinomial Naive Bayes.

Figura 6. Distribución de emociones en los comentarios

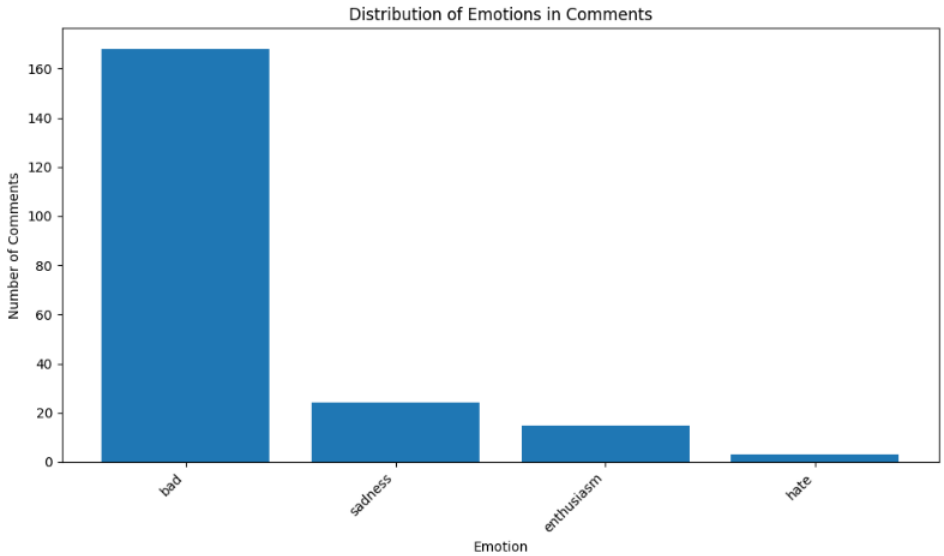

Fuente propia: Elaboración propia con Google Colab

De manera evidente, la emoción predominante es **"bad" (malo)**, con una cantidad notablemente superior al resto, superando los 160 comentarios. Esto indica que una gran proporción de los usuarios expresa experiencias negativas o insatisfacción. Las emociones **"sadness" (tristeza)** y **"enthusiasm" (entusiasmo)** aparecen en una proporción considerablemente menor, lo cual sugiere que, aunque hay presencia de sentimientos emocionales más específicos, como frustración o aprecio, estos no son mayoritarios. Finalmente, la categoría **"hate" (odio)** es la menos frecuente, lo cual, aunque puede parecer positivo, sigue revelando que existe una fracción de usuarios con experiencias extremadamente negativas.

La gráfica refuerza los hallazgos del análisis de sentimiento: el enfoque emocional de los comentarios está fuertemente inclinado hacia lo negativo, lo que puede interpretarse como una señal de alarma para la organización, ya que refleja un grado importante de insatisfacción del cliente que debería ser abordado mediante estrategias de mejora en la experiencia del usuario ante el servicio prestado.

4. Conclusiones

El análisis de sentimientos aplicado a los comentarios de los clientes de Bancolombia evidenció una percepción predominantemente negativa respecto a la nueva aplicación móvil. Este hallazgo refuerza la importancia de escuchar la voz del cliente como un insumo esencial para la mejora continua de productos y servicios digitales. Las técnicas de procesamiento de lenguaje natural (NLP)

y aprendizaje automático permitieron no solo clasificar los comentarios en categorías emocionales, sino también identificar con precisión patrones lingüísticos asociados a la satisfacción o insatisfacción del usuario.

A través del entrenamiento de un modelo multinomial y la evaluación de su rendimiento mediante matrices de confusión, se demostró que el sistema tiene alta efectividad en la detección de comentarios negativos, aunque presenta limitaciones en la identificación de sentimientos neutros y positivos, lo cual sugiere la necesidad de mejorar la calidad del dataset o explorar técnicas de balanceo y afinamiento del modelo.

Los resultados muestran cómo la ingeniería de datos y el análisis semántico pueden ser herramientas valiosas para diagnosticar de forma automatizada el estado de la relación cliente-empresa. En este caso, el predominio de términos como "no funciona", "problemas" o "lenta" dentro de los comentarios negativos alerta sobre aspectos puntuales que deben ser revisados por el equipo de desarrollo y atención al cliente de Bancolombia.

Asimismo, la visualización de las emociones específicas —como "bad", "sadness" y "enthusiasm"— permite comprender más allá de la polaridad básica, revelando matices emocionales que enriquecen el análisis tradicional de opiniones. Esta dimensión emocional puede convertirse en una guía para diseñar respuestas más humanas, empáticas y centradas en la experiencia del usuario.

Se concluye que el uso de análisis de sentimientos es una estrategia poderosa para empresas del sector financiero, no solo como mecanismo de control reputacional, sino como soporte para la innovación centrada en el cliente. Su implementación sistemática puede ayudar a detectar alertas tempranas, fortalecer la fidelización y ajustar las estrategias digitales de manera ágil y basada en evidencia.

5. Referencias

- Plazas, S., Mejía, J., y Montoya, L. (2021). Inteligencia artificial para la gestión de relaciones con los clientes en el sector financiero. Revista Científica General José María Córdova, 19(34), pp. 123-142.
- García, R., y Herrera, C. (2018). Implementación de técnicas de análisis de sentimientos en la banca. *Proceedings of Simposio Colombiano de Computación*, Vol. 1, Medellín, pp. 101-107.
- Liu, B. (2012). Sentiment Analysis and Opinion Mining. Morgan & Claypool Publishers. https://doi.org/10.1007/978-3-031-02145-9
- Aggarwal, C. C. (2015). Data Mining: The Textbook. Springer. https://doi.org/10.1007/978-3-319-14142-8
- Romero, J. (2019). Minería de textos: Técnicas y herramientas para el análisis de opiniones. Editorial Alfaomega.
- Peña, D. (2017). Fundamentos de minería de datos. Editorial Paraninfo.
- Bancolombia. (2024). Historia y evolución institucional. Recuperado el 22 de abril de 2025 de https://www.grupobancolombia.com/corporativo/conocenos/historia

- Facebook Bancolombia. (2024). Comentarios de clientes extraídos de publicaciones oficiales. Consultado el 10 de abril de 2025 en https://www.facebook.com/Bancolombia
- Twitter Bancolombia. (2024). Comentarios de clientes extraídos de publicaciones oficiales. Consultado el 10 de abril de 2025 en https://twitter.com/Bancolombia
- Instagram Bancolombia. (2024). Comentarios de clientes extraídos de publicaciones oficiales. Consultado el 10 de abril de 2025 en https://www.instagram.com/bancolombia

Sobre los autores

- **Paula Ximena Pérez García**: Estudiante de Ingeniería Industrial de Universidad Santo Tomás. paulaperezg@usantotomas.edu.co
- **Karen Milena Rodríguez Díaz**: Estudiante de Ingeniería Industrial de Universidad Santo Tomás. karenrodriguezd@usantotomas.edu.co
- **Ernesto Mendieta Sabogal**: Profesor de Ingeniería Industrial de Universidad Santo Tomás. ernestomendieta@usta.edu.co

---

Los puntos de vista expresados en este artículo no reflejan necesariamente la opinión de la Asociación Colombiana de Facultades de Ingeniería.

Copyright © 2025 Asociación Colombiana de Facultades de Ingeniería (ACOFI)