Análisis de sentimientos Avianca

Laura Sofía Guerrero Guavita, Gabriela Zipaquirá Antolínez, Francy Rocío Castellanos Oviedo

Universidad Santo Tomás
Bogotá, Colombia

Resumen

La industria aérea enfrenta desafíos constantes debido a la alta competencia, las fluctuaciones en la demanda y la necesidad de mantener altos estándares de servicio en un entorno altamente regulado. En este contexto, la percepción del cliente juega un papel fundamental en la reputación y sostenibilidad de las aerolíneas, ya que influye directamente en la fidelización de los pasajeros y en la diferenciación dentro del mercado. Dado el crecimiento exponencial del uso de redes sociales y plataformas de reseñas, estas se han convertido en una fuente valiosa de información sobre la experiencia del cliente.

Este estudio se enfocó en el análisis de sentimientos aplicado a los comentarios de pasajeros sobre Avianca en redes sociales, foros y plataformas de reseñas. El objetivo principal fue evaluar la percepción de los usuarios y proporcionar información relevante para la gestión estratégica y operativa de la aerolínea. Para ello, se implementó un proceso de recolección y minería de datos a gran escala, donde se aplicaron técnicas avanzadas de procesamiento de lenguaje natural (NLP) y aprendizaje automático (ML) con el fin de clasificar automáticamente los comentarios en dos categorías principales de sentimiento: positivo y negativo.

Para la ejecución del análisis, se emplearon algoritmos de clasificación de opiniones junto con técnicas de minería de datos para la limpieza y preprocesamiento de la información. Estos algoritmos permiten desarrollar modelos automatizados que optimizaron el análisis de grandes volúmenes de datos en tiempo real. Además, el uso de enfoques de aprendizaje automático posibilitó la replicabilidad del proceso en futuras evaluaciones, garantizando su continuidad sin necesidad de intervención manual intensiva.

Los resultados muestran que la comodidad, eficiencia del servicio y atención al cliente influyen positivamente en la percepción de los pasajeros, mientras que los retrasos, la gestión del equipaje y la atención en imprevistos generan comentarios negativos. El análisis de sentimientos permite a Avianca identificar fortalezas y áreas de mejora, optimizando procesos y estrategias de fidelización. Además, el uso de inteligencia artificial en la gestión estratégica le ayuda a anticipar

DOI: https://doi.org/10.26507/paper.4548

tendencias, responder proactivamente a las necesidades de los pasajeros y fortalecer su competitividad en el mercado aéreo.

Palabras clave: análisis de sentimientos; redes sociales; percepción del cliente; gestión estratégica

Abstract

The airline industry faces constant challenges due to high competition, fluctuations in demand, and the need to maintain high service standards in a highly regulated environment. In this context, customer perception plays a fundamental role in the reputation and sustainability of airlines, as it directly influences passenger loyalty and market differentiation. Given the exponential growth in the use of social media and review platforms, these have become a valuable source of information about the customer experience.

This study focused on sentiment analysis applied to passenger comments about Avianca on social media, forums, and review platforms. The main objective was to evaluate user perception and provide relevant insights for the airline's strategic and operational management. To achieve this, a large-scale data collection and mining process was implemented, using advanced natural language processing (NLP) and machine learning (ML) techniques to automatically classify comments into two main sentiment categories: positive and negative.

For the analysis, opinion classification algorithms were used along with data mining techniques for cleaning and preprocessing the information. These algorithms allowed for the development of automated models that optimized the analysis of large volumes of data in real time. Additionally, the use of machine learning approaches enabled the replicability of the process in future evaluations, ensuring its continuity without the need for intensive manual intervention.

The results show that comfort, service efficiency, and customer care positively influence passenger perception, while delays, baggage handling, and response to unforeseen events generate negative comments. Sentiment analysis enables Avianca to identify strengths and areas for improvement, optimizing processes and loyalty strategies. Furthermore, the use of artificial intelligence in strategic management helps anticipate trends, proactively respond to passenger needs, and strengthen competitiveness in the airline market.

Keywords*: sentiment analysis; social media; customer perception; strategic management*

1. Introducción

En la actualidad, la lealtad de los pasajeros se ha convertido en un elemento clave para la sostenibilidad de las aerolíneas, dada la creciente exigencia de los clientes y la necesidad de ofrecer un servicio de alta calidad en un entorno altamente competitivo (Jahmani et al., 2020). En este escenario, la percepción del cliente influye de manera directa en la reputación, rentabilidad y

posicionamiento de las compañías aéreas. Durante las últimas dos décadas, la industria ha experimentado un crecimiento vertiginoso, impulsado por la liberalización del mercado, la aparición de aerolíneas de bajo costo y la evolución tecnológica (Chung et al., 2020). Esto ha obligado a las empresas del sector a adaptar sus estrategias y centrar sus esfuerzos en mejorar la experiencia del pasajero.

Avianca, fundada en 1919, es una de las aerolíneas más importantes de América Latina y la segunda más antigua del mundo en operación continua. Con una extensa red de rutas que conecta América con Europa y diversas regiones, la compañía ha evolucionado para adaptarse a los cambios del mercado. Su enfoque en la digitalización y la mejora del servicio al cliente ha sido clave en su estrategia de competitividad (Cano, et al., 2021).

Precisamente estas estrategias llevan consigo desafíos en términos de la creación de procesos que les permitan recolectar y usar esos datos para la toma de decisiones en diversos contextos.

Una alternativa es el análisis de sentimientos, también conocido como minería de opinión y como una herramienta fundamental para evaluar la percepción del cliente. Se trata de una rama del procesamiento del lenguaje natural que permite examinar y clasificar automáticamente opiniones, emociones y percepciones expresadas en textos escritos (López et al., 2022). Su aplicación permite comprender la experiencia del pasajero y detectar patrones en los comentarios que los usuarios dejan en redes sociales, foros y plataformas de reseñas. Como se ha señalado, "Al comprender los sentimientos detrás de las opiniones, las empresas pueden mejorar la satisfacción del cliente, aumentar la reputación de la marca y, en última instancia, aumentar los ingresos" (Ramírez & Mendoza, 2021).

Adicionalmente, el análisis de sentimientos se apoya en técnicas de análisis y minería de datos, las cuales permiten transformar grandes volúmenes de información no estructurada en conocimiento útil para la toma de decisiones (Moreno et al., 2020). Estas técnicas se integran con métodos de procesamiento de lenguaje natural (PLN), que posibilitan automatizar el reconocimiento de patrones lingüísticos y emocionales en los textos (Villalba & Vilares, 2020). Dentro del análisis de resultados, herramientas como la matriz de confusión son indispensables para evaluar el desempeño de los modelos de clasificación, ya que permiten validar su precisión y exactitud al categorizar comentarios como positivos o negativos (García et al., 2021).

El objetivo de este estudio es identificar tendencias y emociones predominantes que permitan reconocer las principales fortalezas y áreas de mejora en la experiencia del pasajero. A partir de estos hallazgos, Avianca podrá optimizar su servicio, fortalecer su relación con los clientes y tomar decisiones estratégicas basadas en datos, lo que contribuirá a mejorar su competitividad en la industria aérea.

Desde una perspectiva organizacional, este análisis es fundamental para la gestión estratégica y operativa de la aerolínea. Al proporcionar información en tiempo real sobre la percepción del cliente, Avianca podrá ajustar sus procesos internos y mejorar la calidad del servicio. Además, "al analizar los comentarios de los clientes con un análisis de sentimientos, las aerolíneas pueden entender mejor qué es lo que más les importa a los clientes" (Castro et al., 2020), lo que permitirá

implementar planes de acción que refuercen su imagen corporativa, impulsen la innovación en la oferta de servicios y fortalezcan su ventaja competitiva (Pérez et al., 2020).

2. Metodología

El estudio comenzó con la recolección de una muestra de más de 500 comentarios realizados por usuarios en las publicaciones más recientes de Avianca en TikTok e Instagram, abarcando desde junio de 2024 hasta abril de 2025. Estos comentarios, en su mayoría, hacían referencia directa a experiencias personales con la aerolínea, lo que los convierte en una fuente valiosa para evaluar la percepción del cliente.

Para el análisis de estos datos, se aplicaron dos enfoques metodológicos complementarios. En primer lugar, se utilizaron modelos preentrenados de análisis de sentimientos: **VADER** (Valence Aware Dictionary and sEntiment Reasoner), diseñado para detectar la polaridad de textos y clasificar emociones de forma multicategórica (Elbagir et al., 2019), y **RoBERTa**, un modelo basado en arquitecturas de lenguaje profundo que genera representaciones contextuales de las palabras, capturando matices y significados del texto con mayor precisión (Tan et al., 2023).

En segundo lugar, se desarrolló un modelo adaptado utilizando regresión logística, para entrenar un modelo a partir de la vectorización de los textos mediante la técnica TF-IDF, limitando el número de características a un máximo de 2000. Este modelo fue entrenado con un tope de 500 iteraciones, a fin de garantizar su convergencia y estabilidad durante el aprendizaje. Para validar la efectividad del modelo entrenado, el conjunto de datos fue dividido en dos subconjuntos: entrenamiento (75%) y prueba (25%). La evaluación del desempeño se llevó a cabo mediante métricas como la precisión y el F1-score, haciendo especial énfasis en el análisis de matrices de confusión normalizadas. Estas matrices permitieron una visualización clara del rendimiento del modelo al clasificar correctamente las opiniones positivas y negativas, tanto en el conjunto de entrenamiento como en el de prueba.

Como lo menciona López (2021) "la matriz de confusión nos permite tener una mejor idea de cómo está clasificando nuestro modelo, ya que proporciona un conteo de los aciertos y errores de cada una de las clases por las que clasificamos". Esta evaluación fue fundamental para identificar posibles sesgos, sobreajuste o desbalance entre las clases, y contribuyó al análisis interpretativo de los resultados obtenidos.

3. Resultados

Inicialmente, se implementaron los modelos preentrenados VADER y RoBERTa (Figura 1) con el objetivo de clasificar los comentarios recolectados en redes sociales según su polaridad emocional. Sin embargo, ambos modelos presentaron limitaciones importantes al aplicarse a textos en español. Estas deficiencias se evidenciaron al contrastar las clasificaciones generadas automáticamente con una evaluación manual: la mayoría de los comentarios fueron clasificados como "neutrales", a pesar de contener expresiones claramente positivas o negativas.

Figura 1. Gráfico comparación Vader vs RoBERTa

Fuente: Elaboración propia.

Se realizó una comparación visual entre los resultados obtenidos por ambos modelos. Como se observa en la Figura 1, tanto VADER como RoBERTa tienden a concentrar la mayoría de las predicciones en la categoría *Neutral*. Esta tendencia es especialmente visible en los ejes vader_neu y roberta_neu, donde se aprecia una alta densidad de puntos naranjas. Las curvas de distribución que acompañan cada dimensión refuerzan esta observación, mostrando una baja presencia relativa de clasificaciones positivas o negativas.

Ante estas limitaciones, se optó por desarrollar un modelo supervisado basado en Regresión Logística en combinación con la técnica de vectorización TF-IDF. Esta metodología permitió construir un clasificador más adecuado para el contexto idiomático del estudio.

La distribución de clases fue la siguiente:

Tabla 1. Distribución de clases

Conjunto	Comentarios positivos	Comentarios negativos
Entrenamiento	195	254
Prueba	57	93

Fuente: Elaboración propia

Posteriormente se procede a realizar el entrenamiento del modelo con Regresión logística. Se obtuvo una precisión del 96.6% en el conjunto de entrenamiento y 86.6% en el conjunto de prueba, lo cual indica un rendimiento robusto con una tendencia leve al sobreajuste. Para comprender mejor el comportamiento del modelo, se emplearon matrices de confusión normalizadas, que ofrecen una visión detallada sobre los aciertos y errores del clasificador para cada clase.

Figura 2. Matriz de confusión – Entrenamiento

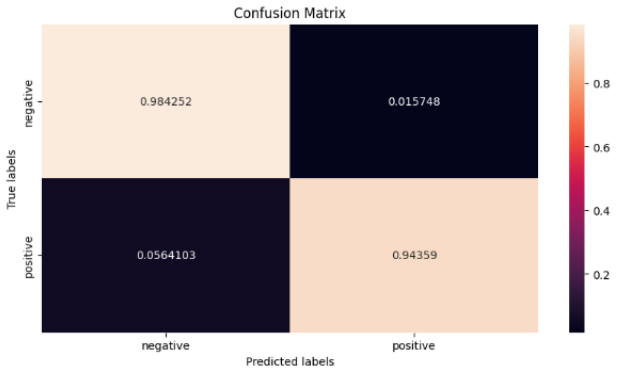

Fuente: Elaboración propia

En el conjunto de entrenamiento, el modelo identificó correctamente el 98.4% de los comentarios negativos y el 94.4% de los comentarios positivos. Esto sugiere un excelente ajuste a los datos de entrenamiento, con un bajo nivel de errores en ambas clases.

Figura 3. Matriz de confusión – Prueba

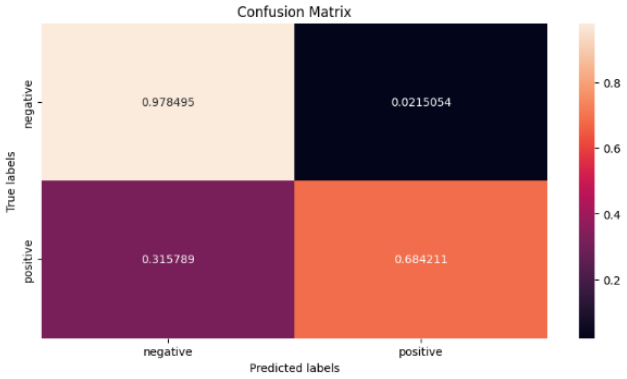

Fuente: Elaboración propia

En la prueba, el modelo mantuvo un alto rendimiento en la clasificación de comentarios negativos (97.8% de precisión), pero su precisión en comentarios positivos fue considerablemente más baja, alcanzando solo un 68.4%, con un 31.6% de falsos negativos (comentarios positivos clasificados incorrectamente como negativos). Esto confirma la hipótesis del impacto del desbalance de clases y resalta la necesidad de incorporar técnicas de balanceo o modelos más robustos en trabajos futuros.

Adicionalmente, se realizó un análisis léxico de las palabras que mayor influencia tuvieron en la clasificación, lo que permite interpretar cualitativamente el comportamiento del modelo. Entre las palabras más asociadas a comentarios positivos se destacan: "mejor" (2.18), "siempre" (2.06), "excelente" (2.02) y "amo" (1.40). Por otro lado, las palabras más recurrentes en los comentarios negativos incluyen: "no" (-2.51), "peor" (-2.43) y "pésimo" (-1.09), evidenciando insatisfacción, negación y opiniones contundentes sobre experiencias negativas.

Es importante aclarar que los valores numéricos asignados a cada palabra corresponden a los coeficientes calculados por la Regresión Logística durante el entrenamiento. Estos pesos indican la influencia de cada término sobre la clasificación final: valores positivos altos aumentan la probabilidad de que un comentario se clasifique como positivo, mientras que valores negativos altos favorecen su clasificación como negativo.

Este análisis permite comprender cómo las expresiones de los usuarios influyen en la clasificación automática y refuerza la conclusión derivada de las matrices de confusión: el modelo identifica mejor los patrones negativos, debido tanto a su mayor frecuencia como a la claridad y contundencia del lenguaje empleado en dichos comentarios. Esto sugiere la importancia de equilibrar las clases y considerar estrategias de enriquecimiento del vocabulario positivo para mejorar la sensibilidad del modelo hacia opiniones favorables.

Con el fin de complementar el análisis de sentimientos realizado sobre las opiniones expresadas por los usuarios en redes sociales frente al servicio de Avianca, se diseñaron dos nubes de palabras: una correspondiente a los comentarios con polaridad positiva y otra a los de polaridad negativa (Figura 4).

Estas visualizaciones permiten identificar de manera inmediata los términos más representativos utilizados por los pasajeros al describir sus experiencias. En la nube de comentarios positivos, predominan palabras como "excelente", "gracias", "viaje", "buena" y "atención", lo que sugiere una valoración favorable hacia aspectos como el servicio recibido, la experiencia de vuelo y la atención del personal. Esto refleja la capacidad de la aerolínea para generar percepciones satisfactorias en ciertos segmentos de clientes.

Figura 4. Nube de palabras más positivas y negativas

a) Más positivas b) Más negativas

Fuente: Elaboración propia.

Por otro lado, en la nube de comentarios negativos sobresalen términos como “peor”, “pésimo”, “maleta”, “reembolso”, “mala” y “nunca”, lo que evidencia la existencia de experiencias negativas asociadas principalmente a problemas con el equipaje, demoras, mala atención o dificultades en la devolución de dinero. Este tipo de términos no solo revela los puntos críticos del servicio, sino también emociones intensas como frustración y enojo, las cuales tienen un alto impacto en la reputación digital de la marca.

4. Conclusión

Este estudio puso de manifiesto el valor del análisis de sentimientos como una herramienta estratégica para comprender la percepción de los clientes de Avianca. A partir de la recolección y procesamiento de más de 500 comentarios en redes sociales, fue posible identificar tanto los factores que generan mayor satisfacción entre los pasajeros —como la comodidad, la eficiencia del servicio y la atención al cliente—, como los principales motivos de insatisfacción, entre los que se destacan los retrasos, problemas con el equipaje y una atención deficiente ante imprevistos.

La implementación de un modelo supervisado mediante Regresión Logística con vectorización TF-IDF permitió superar estas barreras lingüísticas. Este enfoque ofreció resultados más precisos y representativos, aunque mostró una leve tendencia al sobreajuste y una menor sensibilidad para identificar correctamente los comentarios positivos en el conjunto de prueba.

Los hallazgos obtenidos resaltan cómo beneficiarse considerablemente del uso sistemático del análisis de sentimientos. Esta técnica no solo permite monitorear y entender la voz del cliente en tiempo real, sino también anticipar tendencias, optimizar procesos internos, mejorar la experiencia del pasajero y fortalecer su posicionamiento competitivo en un entorno altamente dinámico y exigente como el de la industria aérea.

5. Referencias

- Cano, P., Pérez, M., & Gómez, D. (2021). Digitalización y estrategias competitivas en la industria aérea latinoamericana. *Revista Latinoamericana de Administración, 19*(1), 45-63. https://doi.org/10.1108/RLA-04-2021-0037
- Castro, J., Morales, L., & Rojas, A. (2020). Customer Experience Management: Sentiment Analysis in the Airline Industry. *Journal of Air Transport Management, 87*, 101856. https://doi.org/10.1016/j.jairtraman.2020.101856
- Elbagir, S., & Yang, J. (2019, March). Twitter sentiment analysis using natural language toolkit and VADER sentiment. In *Proceedings of the international multiconference of engineers and computer scientists* (Vol. 122, No. 16). International Association of Engineers
- Chung, C., Koo, B., & Shin, S. (2020). Competition and innovation in the airline industry: A network-based approach. *Transport Policy, 99*, 136-145. https://doi.org/10.1016/j.tranpol.2020.08.004
- García, R., Díaz, C., & Martín, N. (2021). Evaluación de modelos de clasificación en minería de opiniones mediante matrices de confusión. *Ingeniería y Universidad, 25*(2), 33-52. https://doi.org/10.11144/Javeriana.iyu25-2.emco
- Jahmani, A., Bourini, I., & Jawabreh, O. A. (2020). La relación entre la calidad del servicio, la satisfacción del cliente, el valor percibido y la fidelidad del cliente: un estudio de caso de Fly Emirates. *Cuadernos de Turismo, (45)*, 219–238. https://doi.org/10.6018/turismo.426101
- López, P., Sánchez, D., & Ruiz, J. (2022). Natural Language Processing aplicado al análisis de opiniones en redes sociales. *Revista de Informática Teórica y Aplicada, 29*(1), 1-16. https://doi.org/10.22456/2175-2745.107191
- López Condori, J. J., & Gonzales Saji, F. O. (2021). Análisis de sentimiento de comentarios en español en Google Play Store usando BERT. *Ingeniare. Revista chilena de ingeniería, 29*(3), *557-563*.
- Moreno, J., García, M., & Ortega, L. (2020). Data mining and big data analytics for the management of customer feedback. *Technological Forecasting and Social Change, 161*, 120294. https://doi.org/10.1016/j.techfore.2020.120294
- Pérez, A., Martínez, J., & Vargas, P. (2020). Organizational strategies through sentiment analysis: The case of airlines. *Journal of Business Research, 112*, 383-390. https://doi.org/10.1016/j.jbusres.2019.11.029
- Ramírez, F., & Mendoza, E. (2021). El análisis de sentimientos como herramienta de marketing digital en empresas de servicios. *Revista Venezolana de Gerencia, 26*(94), 631-651. https://doi.org/10.52080/rvgluz.26.e94.19
- Tan, K. L., Lee, C. P., & Lim, K. M. (2023). RoBERTa-GRU: A Hybrid Deep Learning Model for Enhanced Sentiment Analysis. *Applied Sciences, 13*(6), 3915. https://doi.org/10.3390/app13063915
- Villalba, L., & Vilares, J. (2020). Procesamiento de lenguaje natural en análisis de sentimientos para empresas. *Procesamiento del Lenguaje Natural, 64*, 1-8. https://doi.org/10.26342/2020-64-1

Sobre los autores

- **Laura Sofía Guerrero Guavita**: Estudiante séptimo semestre, Ingeniería Industrial, Universidad Santo Tomás. Laura.guerrerog@usantotomas.edu.co.
- **Gabriela Zipaquirá Antolínez**: Estudiante séptimo semestre, Ingeniería Industrial, Universidad Santo Tomás. Zipaquiragabriela@usantotomas.edu.co.

- **Francy Rocío Castellanos Oviedo**: Docente Ingeniería Industrial. Universidad Santo Tomás. Francycastellanos@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)