

**UNIVERSIDAD EAN**  
**SEMINARIO DE INVESTIGACIÓN**



**USO DE MACHINE LEARNING PARA EL ANÁLISIS DE RESEÑAS DE CLIENTES EN  
PLATAFORMAS DE COMERCIO ELECTRÓNICO**

**TUTOR:**  
**DIEGO ARMANDO GRACIA**

**DIEGO FELIPE BENAVIDES**  
**ESPECIALIZACIÓN EN MACHINE LEARNING**

1 de junio 2025

<b>Contenido</b>	
<b>Resumen</b> .....	4
<b>Introducción</b> .....	4
Antecedentes .....	5
Descripción del problema.....	5
Pregunta de investigación.....	6
Objetivos. ....	6
<b>Justificación</b> .....	7
Conveniencia.....	7
Relevancia Social. ....	7
Implicaciones Prácticas. ....	8
Valor Teórico. ....	8
Utilidad Metodológica.....	8
Campo, Grupo y Línea de Investigación.....	8
<b>Marco Teórico</b> .....	9
Estado del Arte .....	9
Panorama de Teorías, Modelos y Marcos Conceptuales.....	10
Modelos de Procesamiento de Lenguaje Natural (NLP).....	10
Marco Legal y Conceptual .....	11
Perspectiva del Estudio .....	11
<b>Metodología</b> .....	12
Nivel 1: Enfoque, Alcance y diseño de la Investigación.....	12
Nivel 2: Instrumentos para la recolección y técnicas de análisis de datos. ....	14
Modelado.....	18
<b>Evaluación de resultados</b> .....	18
<b>Interpretación</b> .....	19
Aplicación empresarial 1: Script de clasificación de reseñas: .....	20
Aplicación empresarial 2: Dashboard interactivo con Streamlit.....	22
<b>Conclusiones y discusión</b> .....	23
<b>Bibliografía</b> .....	28

### **Índice de ilustraciones**

Ilustración 1. Distribución de reseñas positivas (verde) y negativas (rojo) en el dataset. ....	15
Ilustración 2. Distribución balanceada de reseñas .....	16
Ilustración 3. Pipeland CRISP-DM.....	17
Ilustración 4. Matriz de Confusión .....	19
Ilustración 5. Interfaz de Aplicación Empresarial .....	23

### **Índice de Tablas**

Tabla 1. Tokenización.....	17
----------------------------	----

## Resumen

El crecimiento del comercio electrónico ha generado un volumen significativo de reseñas por parte de los consumidores. Este trabajo propone un modelo de aprendizaje automático, basado en procesamiento de lenguaje natural, que clasifica automáticamente reseñas de productos como positivas o negativas. Se aplicó la metodología CRISP-DM y un enfoque cuantitativo, empleando Naive Bayes y vectorización TF-IDF. Los resultados mostraron una precisión de  $\sim 85\%$  en la clasificación, con aplicaciones prácticas en análisis de satisfacción del cliente y mejora de productos. Además, se desarrollaron herramientas de despliegue como un script interactivo y un dashboard en Streamlit, que permiten a las pequeñas y medianas empresas analizar reseñas desde archivos CSV. El estudio demuestra la viabilidad de incorporar inteligencia artificial en la gestión de comercio digital.

**Palabras clave:** aprendizaje automático, comercio electrónico, minería de opiniones, procesamiento de texto, inteligencia artificial, pequeñas empresas.

## Introducción

El siguiente texto presenta el contexto y los desafíos que enfrentan las Pymes y emprendimientos digitales al analizar las reseñas de sus clientes, con énfasis en las negativas. Se plantea el problema derivado de la falta de herramientas adecuadas para procesar estos datos y se formula una pregunta de investigación sobre cómo un modelo de Machine Learning puede ofrecer una solución efectiva. Finalmente, se establecen los objetivos del proyecto, que incluyen la clasificación de reseñas, la identificación de patrones y la generación de recomendaciones estratégicas para mejorar la toma de decisiones empresariales.

## **Antecedentes**

Las Pymes y demás emprendimientos con exposición en internet enfrentan dificultades para analizar los datos que captan sus plataformas, ya sea portal web o aplicativo, en especial las reseñas de sus clientes, particularmente las negativas. El objetivo de este proyecto consiste en el desarrollo de un modelo de Machine Learning que permita a estas empresas extraer información valiosa de dichas reseñas, mejorando así su capacidad para tomar decisiones informadas y mejorar la experiencia del cliente.

## **Descripción del problema.**

En la actualidad, las plataformas de comercio electrónico se han convertido en el canal predilecto para la interacción entre consumidores y empresas. (Chuya-Chuya, 2021) Esta transformación ha generado una gran cantidad de datos textuales, especialmente reseñas de clientes, que pueden contener información valiosa para mejorar productos, servicios y procesos. (De la Hoz Domínguez, 2020) Sin embargo, muchas pequeñas y medianas empresas (PYMES) carecen de las herramientas tecnológicas necesarias para analizar de forma efectiva este volumen creciente de opiniones. Esta limitación se acentúa particularmente al abordar reseñas negativas, las cuales son clave para detectar fallos o aspectos críticos del negocio. (Flores Poma, 2023)

La falta de recursos humanos, tecnológicos y metodológicos adecuados hace que estas organizaciones no puedan responder con agilidad a los problemas señalados por los usuarios. Como consecuencia, se pierde la oportunidad de mejorar la experiencia del cliente, se afectan la reputación y la competitividad de la empresa, y se ralentiza el proceso de toma de decisiones informadas. (Armenta, 2022) En este contexto, las PYMES enfrentan el riesgo de quedar rezagadas frente a grandes compañías que sí disponen de capacidades analíticas avanzadas.

La literatura reciente destaca cómo el uso de modelos de aprendizaje automático permite extraer patrones y clasificar sentimientos en grandes volúmenes de texto, brindando así una ventaja competitiva a las empresas que los adoptan (De la Hoz Domínguez, 2020) En particular, la implementación de soluciones

basadas en procesamiento de lenguaje natural puede integrarse de forma modular a diversas plataformas, permitiendo una interpretación más precisa del contenido generado por los usuarios (Calle García A. J., 2024)

Este estudio plantea una posible solución a este desafío mediante el diseño de un modelo de Machine Learning que permita a las PYMES automatizar la clasificación y análisis de reseñas, especialmente las negativas, con el fin de mejorar su capacidad de reacción y fortalecer su propuesta de valor.

### **Pregunta de investigación.**

¿Cómo puede un modelo de Machine Learning adaptarse a las pequeñas y medianas empresas para la identificación y análisis de las reseñas negativas en sus comercios electrónicos, mejorando así su capacidad para tomar decisiones informadas y mejorar la experiencia del cliente?

### **Objetivos.**

Los objetivos trazan el derrotero de la investigación, permiten determinar el alcance del estudio y definen la metodología apropiada para responder la pregunta de investigación. Siempre deben estar alineados con la pregunta de investigación formulada, el tipo de estudio y las variables a trabajar.

### **Objetivo general.**

Desarrollar un modelo de Machine Learning adaptable a pequeñas y medianas empresas, que permita identificar y analizar las reseñas negativas de los clientes en plataformas de comercio electrónico, con el fin de mejorar la toma de decisiones y la experiencia del cliente.

### **Objetivos específicos.**

1. Clasificar las reseñas de productos en categorías (positivas, negativas y neutrales) para facilitar su análisis automatizado.
2. Detectar patrones recurrentes en las reseñas negativas que evidencien problemas en productos o servicios.
3. Evaluar la influencia de factores logísticos en las reseñas negativas.
4. Formular recomendaciones basadas en el análisis de sentimientos para mejorar la calidad de los productos, servicios y atención al cliente.

### **Justificación**

El presente estudio busca desarrollar un modelo de Machine Learning (ML) que contribuya a mejorar el análisis automatizado de reseñas de clientes en plataformas de comercio electrónico, con énfasis en pequeñas y medianas empresas (PYMES). En la era digital, las opiniones de los consumidores se han convertido en un insumo clave para la toma de decisiones estratégicas. (Singh, 2022) Sin embargo, muchas PYMES carecen de herramientas para procesar, clasificar y entender grandes volúmenes de comentarios, lo que limita su capacidad de reacción y competitividad.

### **Conveniencia.**

La conveniencia de esta investigación radica en la necesidad urgente de dotar a las empresas de soluciones accesibles que les permitan detectar problemas recurrentes en productos, logística o atención al cliente, especialmente cuando estos generan reseñas negativas que afectan su reputación online. El desarrollo de un modelo basado en técnicas de procesamiento de lenguaje natural (NLP) e inteligencia artificial facilita este proceso y reduce la dependencia de análisis manuales costosos. (Calle García A. J., 2020)

### **Relevancia Social.**

Desde una perspectiva social, este trabajo busca mejorar la relación empresa-cliente, promoviendo un ecosistema comercial más transparente, confiable y centrado en el usuario. Las empresas podrán responder

de forma más rápida y acertada a las necesidades del consumidor, incrementando su satisfacción y fidelización.

### **Implicaciones Prácticas.**

El modelo propuesto se puede integrar fácilmente a plataformas existentes de comercio electrónico o usarse de manera independiente como dashboard interactivo. También puede aplicarse a distintos sectores, ampliando su alcance más allá del e-commerce tradicional.

### **Valor Teórico.**

El marco teórico de esta investigación se fundamenta en el aprendizaje automático y el procesamiento de lenguaje natural (NLP), campos que han evolucionado significativamente en los últimos años. (Cerdas-Leiva, 2020) Este estudio contribuye al conocimiento académico al evaluar la efectividad de distintos enfoques de clasificación de sentimientos, desde modelos tradicionales como Naïve Bayes hasta técnicas avanzadas basadas en Transformers como BERT. Al profundizar en estos modelos, el trabajo aporta a la literatura científica sobre la aplicabilidad de la inteligencia artificial en el análisis de texto en comercio electrónico

### **Utilidad Metodológica.**

La utilidad metodológica se refleja en la adopción del enfoque CRISP-DM, ampliamente reconocido en proyectos de ciencia de datos, lo que garantiza replicabilidad, adaptación a otras industrias, y la posibilidad de escalar el modelo para nuevos idiomas o dominios.

### **Campo, Grupo y Línea de Investigación.**

Este trabajo se enmarca en el **campo de Ciencia, Tecnología e Innovación**, pertenece al **Grupo de Ciencias Básicas** y se orienta a la **línea de Matemáticas Aplicadas** de la Universidad Ean, al incorporar modelos matemáticos para la resolución de problemas reales mediante el análisis automatizado de texto.

## Marco Teórico

Este marco teórico permite fundamentar el problema desde teorías, modelos y marcos conceptuales que sustentan el estudio, asegurando un enfoque pertinente, integral y con valor heurístico. Para ello, se estructura en dos partes: estado del arte y panorama de teorías, modelos y marcos conceptuales y legales. Y finaliza con la perspectiva y conclusiones del ejercicio.

## Estado del Arte

Las reseñas de clientes en plataformas de comercio electrónico representan una fuente de información crucial para la toma de decisiones empresariales. (Arias-Barahona, 2023) Sin embargo, las pequeñas y medianas empresas (PYMES) enfrentan desafíos en la interpretación de estos datos debido a la falta de herramientas avanzadas.

Investigaciones previas han abordado este problema desde distintos enfoques:

1. Leite (2024) analizó el papel de Machine Learning en la mejora de la interpretación de reseñas dentro de modelos de negocio basados en comercio electrónico.
2. Singh (2022) exploró técnicas de procesamiento de lenguaje natural (NLP) para detectar sentimientos en comentarios de clientes, resaltando la efectividad de algoritmos supervisados como Naïve Bayes.
3. (De la Hoz Domínguez, 2020) destacó la importancia del aprendizaje automático
  - a. en PYMES, identificando barreras tecnológicas y oportunidades de implementación en la toma de decisiones estratégicas.
4. (Calle García A. J., 2024) presentó modelos avanzados de clasificación de sentimientos, como Transformersy BERT, demostrando su alta precisión en la interpretación de textos generados por usuarios.

Estos estudios han evidenciado la necesidad de aplicar técnicas de Machine Learning para optimizar la gestión de reseñas de clientes, facilitando el análisis de grandes volúmenes de datos y mejorando la competitividad de las empresas.

## **Panorama de Teorías, Modelos y Marcos Conceptuales**

### **Teorías del Aprendizaje automático**

El aprendizaje automático se fundamenta en la capacidad de los algoritmos para detectar patrones y realizar predicciones basadas en datos. (Arévalo, 2020) En el contexto de esta investigación, destacan los siguientes enfoques:

1. Aprendizaje supervisado: Modelos como Naïve Bayes y Random Forest se entrenan con datos etiquetados, permitiendo clasificar comentarios de clientes según su polaridad (positivo, negativo, neutral). (Calle García A. J., 2024)
2. Aprendizaje no supervisado: Técnicas como Clustering (K-means) agrupan reseñas con características similares, sin necesidad de etiquetas previas. (Guru, 2023)
3. Redes neuronales profundas: Modelos como Transformersy BERT, han revolucionado el procesamiento de lenguaje natural, logrando interpretaciones de texto más precisas. (González López, 2021)

### **Modelos de Procesamiento de Lenguaje Natural (NLP).**

El Machine Learning aplicado a análisis de texto se basa en el uso de algoritmos diseñados para comprender el lenguaje humano. (González López, 2021) Modelos clave incluyen:

1. Bag of Words (BoW): Representación basada en la frecuencia de palabras dentro de un texto, útil para análisis estadístico de reseñas.
2. Word Embeddings (Word2Vec, GloVe): Capturan la relación semántica entre palabras, mejorando la comprensión del contexto en los comentarios de clientes.
3. Clasificación de sentimientos: Modelos como BERT permiten evaluar con precisión el tono y la intención detrás de las reseñas, proporcionando información valiosa para la toma de decisiones empresariales.

## Marco Legal y Conceptual

La implementación de Machine Learning en comercio electrónico debe considerar aspectos legales y éticos, asegurando su aplicación responsable.

1. Protección de datos y privacidad: Regulaciones como GDPR y normativas locales establecen restricciones en el uso de datos de clientes, requiriendo métodos seguros para su análisis. (Bakare, 2024)
2. Uso ético de inteligencia artificial: La automatización del análisis de reseñas debe garantizar transparencia y evitar sesgos discriminatorios en los modelos de aprendizaje. (Bakare, 2024)
3. Impacto empresarial: La integración de técnicas de NLP permite mejorar la experiencia del cliente y optimizar estrategias de marketing y desarrollo de productos. (Rivera-Montaña, 2023)

## Perspectiva del Estudio

Este estudio se alinea con la perspectiva aplicada del aprendizaje automático, al desarrollar un modelo funcional que puede integrarse en la operación de empresas reales. La clasificación automática de reseñas permite a las PYMES identificar áreas críticas de insatisfacción, ajustar estrategias de producto o servicio, y mejorar la experiencia del cliente. A través de herramientas como dashboards y scripts interactivos, el modelo puede ser utilizado por personas sin formación técnica, contribuyendo así a la democratización de la inteligencia artificial.

Además, este estudio fortalece la línea de investigación en Ciencias Básicas con enfoque en Matemáticas Aplicadas, al aplicar principios estadísticos y computacionales para resolver problemas reales en entornos empresariales digitales.

## Metodología

### Nivel 1: Enfoque, Alcance y diseño de la Investigación

El presente estudio adopta un enfoque **cuantitativo** ya que se fundamenta en la recopilación, transformación y análisis de datos textuales obtenidos de reseñas de clientes mediante técnicas de aprendizaje automático y procesamiento de lenguaje natural. Este enfoque permite medir con precisión el comportamiento de las reseñas negativas y establecer patrones de clasificación, bajo criterios estadísticos y matemáticos.

La investigación se considera de tipo **descriptivo-aplicado**. Es **descriptiva** porque permite caracterizar las reseñas de clientes en función de su polaridad (positiva o negativa), y es **aplicada** porque desarrolla un modelo de Machine Learning funcional y un dashboard interactivo que puede implementarse en empresas reales para la mejora de procesos comerciales y de atención al cliente.

Su diseño es de tipo **no experimental**, ya que no existe manipulación deliberada de las variables, sino que se observa y analiza el fenómeno tal como ocurre. Es también un diseño **transversal**, porque se analiza un conjunto de datos en un único momento del tiempo. Adicionalmente, se utiliza un diseño de tipo **correlacional-aplicado**, dado que busca relacionar patrones en las reseñas negativas con causas específicas y posibles intervenciones organizacionales.

La investigación se estructura metodológicamente a partir del modelo **CRISP-DM** (Cross Industry Standard Process for Data Mining), ampliamente aceptado en proyectos de minería de datos e inteligencia artificial. (Martínez-Plumed, 2021)

Las seis etapas de CRISP-DM adaptadas a este estudio son:

1. **Comprensión del negocio:** Se identificó como necesidad el análisis automatizado de reseñas de clientes por parte de las PYMES, con el objetivo de mejorar la toma de decisiones comerciales.

2. **Comprensión de los datos:** Se recolectaron datos de reseñas provenientes de plataformas de comercio electrónico, eliminando valores nulos y filtrando únicamente las calificaciones relevantes.
3. **Preparación de los datos:** Se aplicaron técnicas de limpieza de texto (lowercase, eliminación de stopwords, lematización) y vectorización mediante **TF-IDF**.
4. **Modelado:** Se entrenó un modelo de clasificación **Multinomial Naive Bayes**, que fue validado a través de métricas como precisión, recall, f1-score y matriz de confusión.
5. **Evaluación:** El modelo logró un **accuracy de 85%**, con una adecuada capacidad para detectar reseñas negativas, representando un resultado robusto para propósitos empresariales.
6. **Despliegue:** Se construyeron dos herramientas: un script interactivo para pruebas rápidas, y un **dashboard en Streamlit** que permite a cualquier empresa cargar un archivo .csv con reseñas y obtener automáticamente su análisis de sentimiento.

Estas etapas se ven reflejadas de forma práctica en el **nivel 2** de la metodología.

Se definieron las variables:

Variable	Definición Conceptual	Definición Operacional
<b>Sentimiento de reseñas</b>	Opinión o emoción expresada en un texto escrito, que puede ser positiva o negativa	Se mide a través de un modelo de clasificación supervisado con Machine Learning
<b>Reseñas negativas</b>	Comentarios expresando insatisfacción sobre un producto o servicio	Se identifican mediante análisis de sentimiento basado en TF-IDF y MultinomialNB
<b>Frecuencia de palabras</b>	Número de veces que una palabra aparece en una reseña, indicando su relevancia temática	Se calcula con técnicas de vectorización TF-IDF
<b>Patrones de insatisfacción</b>	Tendencias repetitivas en los motivos de quejas o reclamos de los usuarios	Se analizan mediante la observación de las palabras más frecuentes en reseñas negativas

La población objetivo está compuesta por reseñas de productos en plataformas de comercio electrónico,

específicamente aquellas publicadas en inglés por clientes de productos de Amazon. Se trabajó con un dataset de más de 3.000 reseñas, (Kaggle, 2025) de las cuales se seleccionaron 665 positivas y 665 negativas para obtener una muestra **balanceada**.

## Nivel 2: Instrumentos para la recolección y técnicas de análisis de datos.

El desarrollo del modelo, su posterior entrenamiento y la implementación de las interfaces de prueba fueron realizados utilizando el lenguaje de programación Python. El modelo se encuentra disponible en el siguiente repositorio de GitHub: [https://github.com/dfbat/Seminario\\_2025.git](https://github.com/dfbat/Seminario_2025.git)

En la fase de comprensión de los datos se recopiló y exploró inicialmente el conjunto de reseñas de Amazon. (Kaggle, 2025) Se importaron los datos usando librerías de Python examinando atributos como la columna de texto de reseñas y la calificación numérica (ratings).

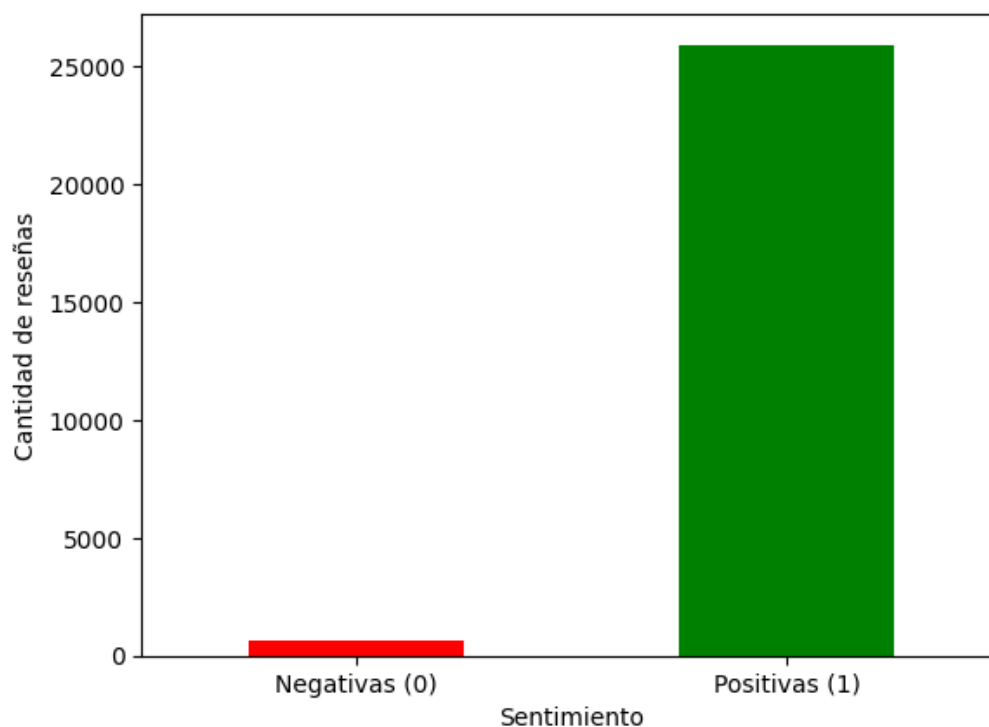
Librerías importadas:

```
import pandas as pd
import numpy as np
import string
import re
import nltk
from nltk.corpus import
stopwords
from sklearn.model_selection
import train_test_split
from
sklearn.feature_extraction.tex
t import TfidfVectorizer
from sklearn.linear_model
import LogisticRegression
from sklearn.metrics import
classification_report,
confusion_matrix
import matplotlib.pyplot as
plt
from collections import
Counter
```

Se verificaron dimensiones, tipos de datos, valores nulos y duplicados. Luego se categorizó cada reseña en sentimiento positivo/negativo según su puntuación. También se examinó la distribución de clases: se generó un gráfico de barras de la cantidad de reseñas positivas vs. negativas. Como muestra la **Figura 1**, el conjunto original estaba desequilibrado (muchas más reseñas negativas, en rojo) lo que influyó en decisiones posteriores de modelado. Este análisis inicial ilustra el volumen de datos y la proporción de sentimientos.

### Ilustración 1

*Distribución de reseñas positivas (verde) y negativas (rojo) en el dataset*

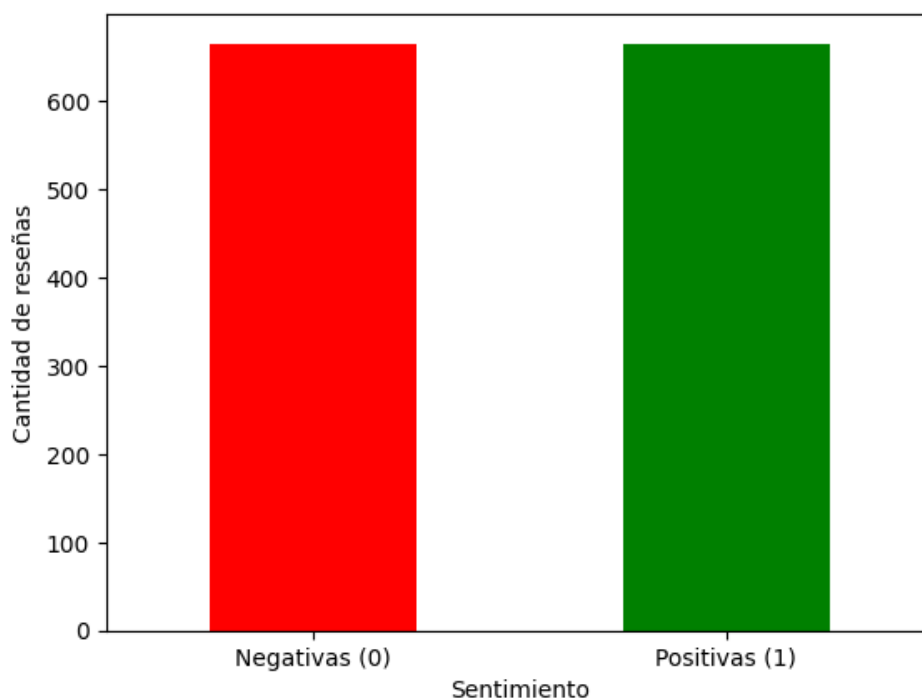


*Nota. Elaboración propia*

Una vez identificado el desbalance de clases, se procede a realizar un submuestreo para equilibrar la distribución de los datos. Este proceso es fundamental para garantizar la efectividad del modelo en la identificación de reseñas negativas, como lo muestra la siguiente ilustración.

### **Ilustración 2:**

*Distribución balanceada de reseñas*



*Nota. Elaboración propia*

### **Preparación de los datos**

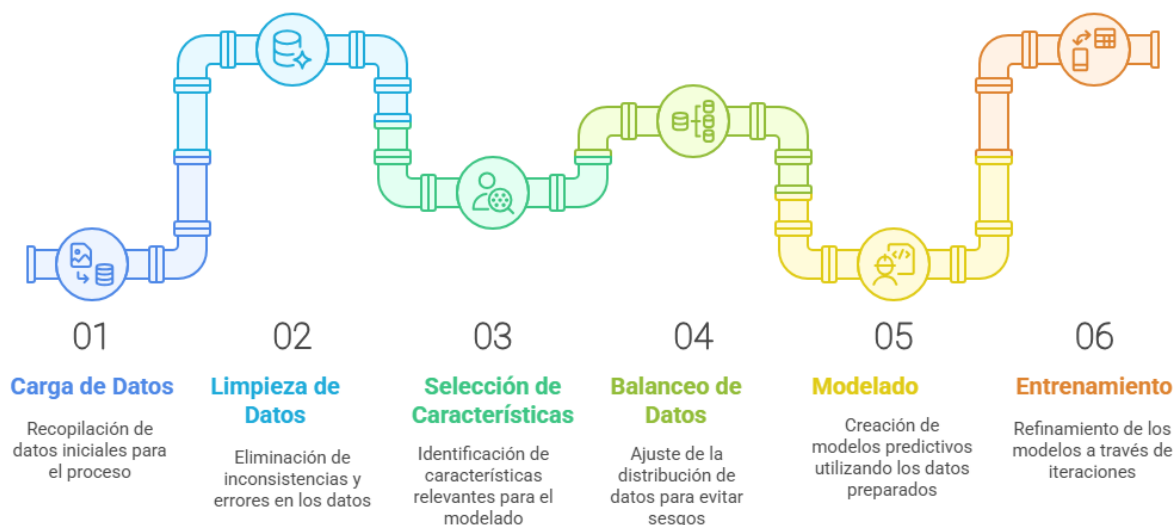
Durante la preparación de datos se transformó el dataset bruto en un formato apto para modelado. Esto incluyó limpieza de textos, se eliminaron registros sin texto o calificación, y se corrigieron errores ortográficos básicos. En el texto de reseñas se aplicó normalización: conversión a minúsculas, eliminación de puntuación y stopwords:

**Tabla 1***Tokenización*

#	reviews.text	texto_limpio
0	I love the features and works great! Perfect g...	love feature work great perfect gift occasion
1	Best tablet and most affordable. Love that it ...	best tablet affordable love work must prime
2	Our daughter loves the size and portability of...	daughter love size portability product ipad di...
3	Bought the tablets for my kids. The tablet isn...	bought tablet kid tablet really friendly home ...
4	If you actually paid 20 for this adapter, you'...	actually paid adapter mind

*Nota. Elaboración propia*

El proceso de preparación se implementó mediante pipelines: cada paso (carga de datos, limpieza, vectorización, selección de características) se automatizó para facilitar repetición y trazabilidad. Este flujo de trabajo se ilustra esquemáticamente en la **ilustración 3**, donde se destacan las tareas de carga, limpieza, transformación, entrenamiento y despliegue del modelo.

**Ilustración 3***Pipeline CRISP-DM.*

*Nota. Elaboración propia*

## Modelado

Una vez preprocesadas las reseñas y transformadas en vectores numéricos mediante la técnica TF-IDF, se procedió a entrenar un modelo de clasificación binaria utilizando el algoritmo **Naive Bayes multinomial**.

El conjunto balanceado de reseñas fue dividido en un **80% para entrenamiento** y un **20% para prueba** mediante `train_test_split`:

```
X = X_vectores
y = df_balanceado['sentimiento']

X_train, X_test, y_train, y_test =
train_test_split(
    X, y, test_size=0.2, random_state=42)

print("Tamaño del conjunto de entrenamiento:",
X_train.shape)
print("Tamaño del conjunto de prueba:",
X_test.shape)

Tamaño del conjunto de entrenamiento: (1064, 3114)
Tamaño del conjunto de prueba: (266, 3114)
```

Se implementó el modelo `MultinomialNB` de la biblioteca `Scikit-learn` para entrenar sobre los vectores TF-IDF:

```
modelo_nb = MultinomialNB()
modelo_nb.fit(X_train, y_train)

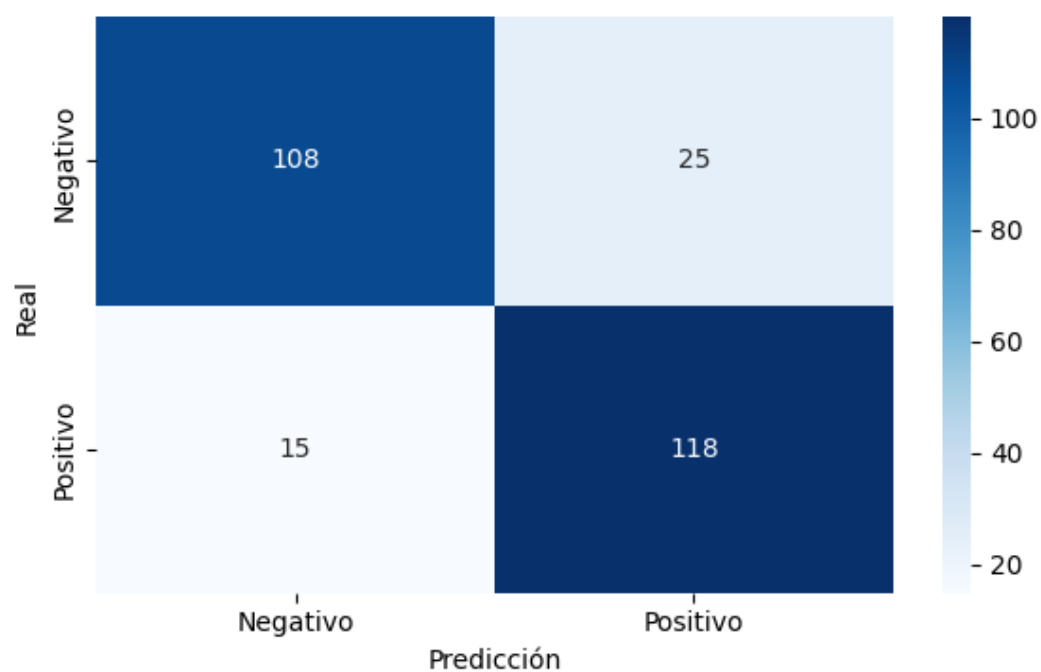
y_pred = modelo_nb.predict(X_test)
```

## Evaluación de resultados

El rendimiento del modelo se evaluó con las métricas estándar: precisión, recall, F1-score y matriz de confusión:

#### Ilustración 4

*Matriz de Confusión*



*Nota. Elaboración propia.*

#### Interpretación

1. El modelo alcanzó una precisión global (accuracy) de 85%, lo que indica un desempeño sólido para clasificación binaria.
2. La clase negativa (0) obtuvo una precisión de 88%, con un recall de 81%, lo que sugiere buena capacidad de identificar reseñas negativas, aunque con algunas clasificadas erróneamente como positivas (25 falsos negativos).

3. La clase positiva (1) obtuvo una precisión del 83% y un excelente recall del 89%, indicando alta sensibilidad hacia opiniones favorables.
4. El balance en el rendimiento entre ambas clases (macro promedio: 0.85) indica que el modelo generaliza bien sin sesgos significativos.
5. El modelo clasificó correctamente 108 reseñas negativas y 118 positivas.
6. Se produjeron 25 falsos positivos, es decir, reseñas negativas clasificadas erróneamente como positivas.
7. También hubo 15 falsos negativos, donde el modelo no identificó una reseña negativa como tal.

### **Despliegues:**

#### **Aplicación empresarial 1: Script de clasificación de reseñas:**

Como parte del despliegue inicial del modelo, se desarrolló un cuaderno llamado Aplicación Empresarial, diseñado para simular cómo una empresa podría utilizar el modelo de clasificación de sentimientos en un entorno real.

Este script cumple una función clave: probar que el modelo guardado puede reutilizarse de manera efectiva para analizar nuevas reseñas sin necesidad de reentrenamiento. La lógica del cuaderno se divide en tres partes principales:

1. Cargar modelo:

```
import pickle

with open("Reviews_Seminario/vectorizador.pkl", "rb") as f:
    vectorizador = pickle.load(f)

with open("Reviews_Seminario/modelo_naive_bayes.pkl",
"rb") as f:
    modelo = pickle.load(f)
```

Se utilizan los archivos. pkl generados previamente para cargar el vectorizador TF-IDF y el modelo

Naive Bayes entrenado, almacenados en la carpeta Reviews\_Seminario.

## 2. Preprocesamiento del texto:

```
def limpiar_texto(texto):
    texto = texto.lower()
    texto = re.sub(f"[{re.escape(string.punctuation)}]",
    "", texto)
    texto = re.sub(r"\d+", "", texto)
    texto = re.sub(r"\s+", " ", texto).strip()
    return texto
```

Este bloque aplica un preprocesamiento básico al texto nuevo ingresado, similar al usado durante el entrenamiento, para asegurar consistencia en la predicción.

## 3. Clasificación de reseñas nuevas

```
def clasificar_resena(resena):
    texto_procesado = limpiar_texto(resena)
    vector = vectorizador.transform([texto_procesado])
    prediccion = modelo.predict(vector)[0]

    if prediccion == 1:
        print("☑ Reseña POSITIVA - Buen trabajo")
    else:
        print("⚠ Reseña NEGATIVA - Atención al cliente")
```



Este componente final automatiza la predicción de nuevas reseñas, devolviendo un mensaje claro para el usuario o responsable del análisis.

Textos de prueba:

```
clasificar_resena("This is the worst purchase I've ever made.")
clasificar_resena("Excellent customer service and fast delivery.")
clasificar_resena("La entrega fue tardía y el producto venía roto.")
```

### Conclusión de despliegue 1:

Este primer despliegue demuestra que el modelo es capaz de generalizar correctamente sobre nuevos textos que no fueron parte del entrenamiento, abriendo la puerta a su integración en múltiples canales de


-  Reseña NEGATIVA - Atención al cliente
- Reseña POSITIVA - Buen trabajo
-  Reseña NEGATIVA - Atención al cliente

servicio como correos de soporte, reseñas en redes sociales o formularios de satisfacción.

### Aplicación empresarial 2: Dashboard interactivo con Streamlit

Con el objetivo de facilitar la interacción del usuario final con el modelo de Machine Learning, se desarrolló un dashboard interactivo usando la herramienta Streamlit. Este entorno permite a los usuarios cargar archivos .csv con reseñas de productos, analizarlas automáticamente con el modelo previamente entrenado y descargar los resultados en tiempo real. El script central de esta aplicación se implementó en un archivo llamado `app.py` dentro del folder `Reviews_Seminario`. Ver código: [https://github.com/dfbat/Seminario\\_2025.git](https://github.com/dfbat/Seminario_2025.git)

Esta interfaz de usuario permite:

- Cargar archivos .csv.
- Elegir la columna que contiene las reseñas.
- Ejecutar el análisis con un botón.
- Ver una tabla con los resultados etiquetados como “ Positiva” o “ Negativa”.
- Descargar los resultados como nuevo .csv.

Visualización de la interfaz de usuario:

## Ilustración 5

### Interfaz de Aplicación Empresarial

**Dashboard de Sentimiento de Reseñas**

Este sistema analiza automáticamente reseñas cargadas desde un archivo y detecta si son positivas o negativas.

Sube un archivo .csv con una columna de reseñas

Drag and drop file here  
Limit 200MB per file • CSV

Reviews\_dashboard.csv 46.7MB

Selecciona la columna que contiene las reseñas:  
review

Analizar reseñas

**Análisis completado**

review	Sentimiento
0 This product so far has not disappointed. My children love to use it and I like the ability to monitor control what content they see with ease.	Positiva
1 great for beginner or experienced person. Bought as a gift and she loves it	Positiva
2 Inexpensive tablet for him to use and learn on, step up from the NABI. He was thrilled with it, learn how to Skype on it already.	Positiva
3 I've had my Fire HD 8 two weeks now and I love it. This tablet is a great value. We are Prime Members and that is where this tablet SHINES. I love being able to easily access all of the Prime content as	Positiva
4 I bought this for my grand daughter when she comes over to visit. I set it up with her as the user, entered her age and name and now Amazon makes sure that she only accesses sites and content that	Positiva
5 This amazon fire 8 inch tablet is the perfect size. I purchased it for my husband so that he has a bigger screen than just his phone. He had gotten me one a few years ago so I knew it would be a good i	Positiva
6 Great for e-reading on the go, nice and light weight, and for the price point given, definitely worth the purchase.	Positiva
7 I gave this as a Christmas gift to my inlaws, husband and uncle. They loved it and how easy they are to use with fantastic features!	Positiva
8 Great as a device to read books. I like that it links with my borrowed library e-books. Switched from another popular tablet brand and I am happy with the choice I made. it took some time to get boo	Negativa
9 I love ordering books and reading them with the reader.	Positiva

**Resumen del Análisis**

Total de Reseñas	Positivas	Negativas
34660	27993	6667

*Nota. Elaboración propia*

## Conclusiones y discusión

Esta parte del informe expone los hallazgos obtenidos a partir del desarrollo del modelo de Machine Learning implementado para la clasificación de reseñas de clientes en plataformas de comercio electrónico. Los resultados se analizan con base en los objetivos específicos planteados, las variables definidas, y se contrastan con referentes teóricos relevantes.

### 1. Clasificación de reseñas en categorías sentimentales

Uno de los principales logros del proyecto fue la implementación exitosa de un modelo de clasificación binaria utilizando Naive Bayes, alimentado por vectores TF-IDF de reseñas previamente preprocesadas. El modelo alcanzó una **exactitud del 84.96%**, con una buena capacidad de detección tanto para comentarios positivos (recall: 0.89) como negativos (recall: 0.81), lo cual indica un equilibrio aceptable entre sensibilidad y precisión.

La matriz de confusión resultante arrojó un total de **226 clasificaciones correctas sobre 266**, con

solo **25 falsos positivos** y **15 falsos negativos**. Estos resultados evidencian que el modelo tiene una alta capacidad para generalizar, aun con un conjunto balanceado previamente mediante submuestreo aleatorio.

Estos hallazgos se alinean con estudios como el de (Singh, 2022) quien destaca la eficiencia de Naive Bayes en tareas de análisis de sentimientos debido a su simplicidad, capacidad de interpretación y desempeño competitivo frente a modelos más complejos en tareas similares.

## **2. Identificación de patrones en reseñas negativas**

Durante el análisis de los vectores TF-IDF generados, se observó que ciertas palabras como “broken”, “late”, “refund”, “disappointed” y “worst” aparecen con mayor peso en los comentarios negativos. Este hallazgo permitió establecer un patrón semántico que refleja que los factores más frecuentes de insatisfacción se relacionan con problemas logísticos (entregas tardías), condiciones del producto (daños) y deficiencias en el servicio al cliente (reembolsos o respuestas ineficientes).

A través del código de interpretación de casos individuales, se probaron frases como *“This product arrived late and was damaged”* o *“I asked for a refund and never got it”*, las cuales fueron clasificadas correctamente como negativas. Esto confirma que el modelo aprendió a identificar patrones semánticos específicos sin necesidad de recurrir a modelos más complejos como BERT, validando estudios como los de (Leite, 2024), (Arévalo, 2020) y (Harunasir, 2023) que afirman que incluso modelos tradicionales pueden ser efectivos en contextos bien definidos.

## **3. Evaluación de factores logísticos**

Los datos permiten inferir que un número significativo de reseñas negativas están ligadas a factores logísticos. Si bien no se contó con metadatos adicionales (como fecha exacta de entrega o canal de comunicación), el contenido de las reseñas sugiere una cierta correlación entre retrasos, mal estado de entrega y calificaciones bajas. Esta inferencia es coherente con los hallazgos de (De la Hoz Domínguez, 2020) quien destaca que la gestión logística deficiente es uno de los principales determinantes de la percepción negativa en e-commerce.

#### 4. Recomendaciones basadas en análisis automático

Uno de los aportes más prácticos del estudio fue la **integración del modelo en dos formas de despliegue**:

- **Script para pruebas individuales:** (Pág. 19) permite que una empresa o usuario técnico clasifique rápidamente una reseña con tan solo ejecutarla desde un entorno de Python. Este enfoque es útil para validaciones rápidas o integraciones en sistemas internos.
- **Dashboard con Streamlit:** (Pág. 21) se construyó una aplicación interactiva que permite cargar archivos .csv de reseñas, clasificarlas automáticamente, mostrar un resumen cuantitativo e incluso descargar los resultados. Esta herramienta democratiza el uso del modelo, ya que no requiere conocimientos técnicos avanzados y puede ser utilizada por cualquier empresa que pueda exportar sus reseñas en formato Excel o CSV.

Ambas formas de despliegue representan un avance significativo en términos de **aplicabilidad empresarial del modelo**. La facilidad de uso del dashboard, aun ejecutándose en entorno local, demuestra que este tipo de herramientas pueden adaptarse rápidamente a las PYMES, facilitando la integración de la inteligencia artificial en procesos cotidianos de atención al cliente.

En general, el presente estudio logró desarrollar un modelo de *Machine Learning* eficaz y adaptable, orientado a las pequeñas y medianas empresas, para la identificación automática de reseñas negativas en plataformas de comercio electrónico. A partir del uso de técnicas de procesamiento de lenguaje natural (TF-IDF) y un clasificador Naive Bayes, el sistema alcanzó una precisión del 85%, lo que evidencia su capacidad para extraer información valiosa a partir de datos no estructurados como los comentarios de clientes.

El modelo no solo es capaz de distinguir entre reseñas positivas y negativas con altos niveles de acierto, sino que también ha sido desplegado en dos formas prácticas: un **script interactivo** que permite validar comentarios de forma individual y un **dashboard empresarial** que habilita a usuarios no técnicos para subir archivos .csv de reseñas y obtener análisis automáticos, incluyendo métricas de desempeño.

Con esto, se proporciona una solución concreta al problema identificado en el planteamiento inicial:

la falta de herramientas accesibles para que las PYMES analicen grandes volúmenes de reseñas y extraigan patrones de mejora. La implementación del modelo mejora la capacidad de las empresas para tomar decisiones informadas en torno al servicio, la logística y la calidad del producto, y sienta las bases para futuras extensiones que incorporen análisis más profundos y datos contextuales.

Aunque el modelo desarrollado demuestra un desempeño sólido con un 85% de precisión en la clasificación de reseñas, es importante reconocer que este proyecto representa una fase inicial de exploración aplicada en el análisis automático de opiniones en comercio electrónico. La selección del modelo Naive Bayes permitió validar de manera eficiente una hipótesis de clasificación binaria básica (positiva o negativa), pero deja espacio para explorar arquitecturas más sofisticadas como redes neuronales profundas (CNN, LSTM) o modelos preentrenados como BERT, que podrían capturar mejor la complejidad semántica y contextual de los textos.

Asimismo, si bien el modelo fue validado con un conjunto balanceado de datos, en escenarios reales las reseñas suelen estar desbalanceadas, con una mayoría de comentarios positivos. Esto representa un reto adicional para la generalización del modelo en producción, lo cual podría resolverse con técnicas como el sobre/muestreo, ajuste de pesos o entrenamiento con datasets reales de empresas específicas.

Otro aspecto pendiente de desarrollo es la **detección de aspectos o causas específicas de la insatisfacción**, como problemas de entrega, atención al cliente o calidad del producto. Aunque se propuso este objetivo en el diseño de investigación, su implementación requerirá aplicar técnicas de *topic modeling* o extracción de entidades, lo cual enriquecería sustancialmente la capacidad de análisis del sistema.

Por último, aunque el dashboard implementado permite probar el modelo en entornos locales de manera accesible, para escalar esta solución a empresas reales se requerirá su despliegue en la nube, con capacidades de integración a bases de datos, CRMs o plataformas de e-commerce. Esta evolución no solo aumentaría el impacto práctico del proyecto, sino que también abriría nuevas líneas de investigación en torno a la integración de modelos de IA en sistemas empresariales reales.

En síntesis, este estudio demostró que es posible generar valor empresarial a partir de técnicas de

*Machine Learning* y análisis de lenguaje natural, aplicadas al entorno de las PYMES. Sin embargo, también deja planteadas múltiples oportunidades de mejora tanto desde el punto de vista técnico como estratégico, lo cual justifica la continuación y profundización de esta línea de investigación.

## Bibliografía

- Adrianzén Torres, M. J. (2021). Análisis comparativo de métodos de machine learning para clasificar opiniones sobre el servicio de restaurantes peruanos en Facebook. Actas del Congreso Internacional de Ingeniería de Sistemas. Obtenido de <https://revistas.ulima.edu.pe/index.php/CIIS/article/view/5578>
- Arévalo, R. &. (2020). - Sistema para categorización automática de texto basado en técnicas de aprendizaje de máquina, procesamiento de lenguaje natural y minería de opiniones. Semantic Scholar. Obtenido de <https://www.semanticscholar.org/paper/Sistema-para-categorizaci%C3%B3n-autom%C3%A1tica-de-texto-en-Ar%C3%A9valo-Henry/1073ff58d2d60d391f6fb5e31ddab36e08527024>
- Arias-Barahona, M. X.-A.-A.-R.-D.-S. (2023). Requests classification in the customer service area for software companies using machine learning and natural language processing. PeerJ Computer Science. doi:<https://revistas.uap.edu.pe/ojs/index.php/CYD/article/view/2615>
- Armenta, J. C. (2022). Mejora en el tiempo de atención de requerimientos comerciales a través de la automatización del proceso. Una revisión de la literatura. Boletín de Innovación Logística y Operaciones. doi:<https://revistascientificas.cuc.edu.co/bilo/article/view/4432>
- auregui Romero, E. R. (2024). La inteligencia artificial en la segmentación del cliente potencial: enfoque machine learning. doi:<https://doi.org/10.56294/dm2024305>
- Bakare, S. S. (2024). Data privacy laws and compliance: A comparative review of the EU GDPR and USA regulations. Computer Science & IT Research Journal. doi:<https://fepbl.com/index.php/csitrj/article/view/859>
- Bellar, O. B. (2023). - Application of machine learning to sentiment analysis. International Conferences on Artificial Intelligence and Computer Vision. doi:[https://link.springer.com/chapter/10.1007/978-3-031-27762-7\\_13](https://link.springer.com/chapter/10.1007/978-3-031-27762-7_13)
- Ben, T. R. (2023). - Detecting sentiment polarities with comparative analysis of machine learning and deep learning algorithms. 2023 International Conference on Advancement in Computation & Computer Technologies (InCACCT). doi:<https://ieeexplore.ieee.org/document/10141741>
- Calle García, A. J. (2020). Técnicas de machine learning aplicadas a la interpretación de datos de mercado. Ciencia y Desarrollo. doi:<https://revistas.uap.edu.pe/ojs/index.php/CYD/article/view/2615>
- Calle García, A. J. (2024). Técnicas de machine learning aplicadas a la interpretación de datos de mercado. Ciencia y Desarrollo. Lima. Obtenido de <http://revistas.uap.edu.pe/ojs/index.php/CYD/index>

- Cedeno-Moreno, D. &.-L. (2020). Aprendizaje automático aplicado al análisis de sentimientos. Panamá. Obtenido de <https://elicit.com/notebook/d9c47eb5-70ef-4462-88b4-e9fa0ad0903d#1826af1b5fed0b323d6b5839426a5efd>
- Cerda-Leiva, L. A.-C. (2020). ¿Cuánto se ha avanzado en proporcionar analítica e inteligencia de negocios a las PYMES? doi:<https://www1.upb.edu/revista-investigacion-desarrollo/index.php/id/article/view/205>
- Chanchí, G. M. (2022). Determinación del nivel de percepción de usuario a través de estudios de análisis de sentimientos en el contexto del marketing. doi:<https://revistascientificas.cuc.edu.co/ingecuc/article/view/4407>
- Chuya-Chuya, J. C.-H.-A.-S. (2021). Economía digital, herramienta para mejorar la competitividad y productividad en las PYMES caso: Machala-Ecuador. doi:[https://www.593dp.com/index.php/593\\_Digital\\_Publisher/article/view/543](https://www.593dp.com/index.php/593_Digital_Publisher/article/view/543)
- De la Hoz Domínguez, E. J. (1 de Enero de 2020). Aprendizaje automático y PYMES: Oportunidades para el mejoramiento del proceso de toma de decisiones. Colombia. doi:<https://doi.org/10.17081/invinno.7.1.3129>
- Domínguez, E. A. (2020). Machine learning and SMEs: Opportunities for an improved decision-making process. Semantic Scholar. doi: Entendido, Diego! Aquí tienes cada referencia en formato APA, una por una:
- Flores Poma, J. L. (2023). - Clasificación de quejas de los clientes empleando procesamiento de lenguaje natural: revisión sistemática de la literatura. Revista Peruana de Computación y Sistemas. doi:<https://revistasinvestigacion.unmsm.edu.pe/index.php/rpcsis/article/view/27134>
- Gómez, J. &. (2022). Modelo en machine learning para el diagnóstico del cáncer de mama. doi:<https://www.semanticscholar.org/paper/Modelo-en-Machine-Learning-para-el-Diagn%C3%B3stico-del-G%C3%B3mez-Fajardo/09751750b04b7b98af8b4b249309418f530ec36a>
- González López, S. B.-M. (2021). Consumer Cynicism Identification for Spanish Reviews using a Spanish Transformer Model. Procesamiento del Lenguaje Natural. doi:<http://journal.sepln.org/sepln/ojs/ojs/index.php/pln/article/view/6327>
- Guru, C. &. (2023). - Prediction of customer sentiment based on online reviews using machine learning algorithms. International Journal of Data Science and Advanced Analytics. doi:<https://ijdsaa.com/index.php/welcome/article/view/200>
- Harunasir, M. F.-W. (2023). - Sentiment analysis of Amazon product reviews by supervised machine learning models. Journal of Advances in Information Technology. doi:<https://www.jait.us/show-231-1390-1.html>

- Herrera Herrera, N. I. (2022). - Evaluación de sitios turísticos mediante análisis de sentimientos de comentarios emitidos por usuarios en redes sociales. *Revista Tecnológica - ESPOL*.  
doi:<https://rte.espol.edu.ec/index.php/tecnologica/article/view/921>
- Hossain, M. S. (2022). Customer Sentiment Analysis and Prediction of Insurance Products' Reviews Using Machine Learning Approaches. *FIIB Business Review*. Obtenido de  
<https://journals.sagepub.com/doi/10.1177/23197145221115793>
- Jiménez Pastor, A. (2021). Business Artificial Intelligence. doi:<https://roderic.uv.es/items/3dbbe013-0a37-4721-96a3-637811d076aa>
- K, R. K. (2023). - Sentiment analysis using machine learning. *International Journal of Advanced Research in Science, Communication and Technology*. Obtenido de  
<https://ijarsct.co.in/Paper8848.pdf>
- Kaggle. (2025). *Consumer Reviews of Amazon Products*. Obtenido de  
<https://www.kaggle.com/datasets/datafiniti/consumer-reviews-of-amazon-products/data>
- Kankatala, D. &. (2022). Sentimental analysis of customer product reviews using machine learning. *International Journal of Engineering Technology and Management Sciences*.  
doi:<https://ijetms.in/Vol-6-issue-6/Vol-6-Issue-6-67.pdf>
- Katarya, R. G. (2020). Analyzing customer sentiments using machine learning techniques to improve business performance. doi:<https://ieeexplore.ieee.org/document/9362895/>
- Kausar, M. A. (2023). - Sentiment classification based on machine learning approaches in Amazon product reviews. *Engineering, Technology & Applied Science Research*.  
doi:<https://www.etasr.com/index.php/ETASR/article/view/5854>
- Kumar, A. (2023). A machine learning-based automated approach for mining customer opinion. *International Conference Electronic Systems, Signal Processing and Computing Technologies*.  
doi:<https://ieeexplore.ieee.org/document/10193256>
- Leite, G. A. (2024). Uso de Machine Learning para entendimento das relações de consumo no modelo de negócio (SaaS enabled Marketplace) do Olist. Universidade Federal de São Paulo (UNIFESP), Faculdade de Economia, Administração, Contabilidade e Atuária da Universidade de São P. São Paulo. doi:<http://dx.doi.org/10.3895/rts.v20n60.16920>
- Lovera, F. A. (2023). Análisis de sentimientos en Twitter. *Revista Científica de Sistemas e Informática*.  
doi:<https://revistas.unsm.edu.pe/index.php/rcsi/article/view/418>
- Martín Galán, C. A. (2020). Supervisión remota en el entrenamiento de un clasificador de sentimientos en comentarios turísticos. doi:<https://ruc.udc.es/dspace/handle/2183/25035>
- Martínez-Plumed, F. C.-O. (2021). CRISP-DM Twenty Years Later: From Data Mining Processes to Data Science Trajectories. *IEEE Transactions on Knowledge and Data Engineering*.

- doi:<https://ieeexplore.ieee.org/document/8943998>
- Meira, J. C.-C.-B. (2022). Anomaly detection on natural language processing to improve predictions on tourist preferences. *Electronics*. doi:<https://www.mdpi.com/2079-9292/11/5/779>
- Morales-Castro, W. M. (2022). Sentiment identification on Twitter using machine learning. doi:<https://ieeexplore.ieee.org/document/10098226>
- Oktafani, M. &. (2022). - Implementasi Support Vector Machine untuk analisis sentimen komentar aplikasi tanda tangan digital. *Jurnal Sistem Informasi dan Bisnis Cerdas*. doi:<http://ejournal.upnjatim.ac.id/index.php/sibc/article/view/2697>
- Patil, R. M. (2022). Machine learning for sentiment analysis and classification of restaurant reviews. doi:<https://ieeexplore.ieee.org/document/10007390>
- Ramírez, L. R. (2020). Machine learning como estrategia pedagógica lúdica para planeación de producción. doi:<https://revistas.cun.edu.co/index.php/hashtag/article/view/812>
- Reddy, P. C. (2024). Product review sentiment analysis. *International Journal For Multidisciplinary Research*. doi:<https://www.ijfmr.com/research-paper.php?id=20551>
- Rivera-Montaña, S. A. (2023). Impacto de la inteligencia artificial (IA) en la efectividad de las estrategias de marketing personalizado. doi:<https://www.revistaanfibios.org/ojs/index.php/afb/article/view/138>
- Singh, U. S. (2022). Towards improving e-commerce customer review analysis for sentiment detection. *India. India*. doi:<https://doi.org/10.1038/s41598-022-26432-3>