


**PONTIFICIA UNIVERSIDAD CATÓLICA DEL ECUADOR SEDE
ESMERALDAS**



CARRERA

INGENIERÍA DE SISTEMAS Y COMPUTACIÓN

TEMA DE INVESTIGACIÓN:

**SISTEMA DE APRENDIZAJE AUTOMÁTICO PARA EL ANÁLISIS DE SEXISMO
EN EL GÉNERO MUSICAL URBANO**

LÍNEA DE INVESTIGACIÓN:

AUTOMATISMOS Y SISTEMAS INTELIGENTES

PREVIO A LA OBTENCIÓN DEL TÍTULO DE:

INGENIERO DE SISTEMA Y COMPUTACIÓN

AUTOR

DANY DARIO PIANCHICHE AÑAPA

ASESOR:

PABLO PICO VALENCIA (PhD)

ESMERALDAS, 2023

TRIBUNAL DE GRADUACIÓN

Trabajo de tesis aprobado luego de haber dado cumplimiento a los requisitos exigidos por el reglamento de Grado de la PUCESE previo a la obtención del título de INGENIERO DE SISTEMAS Y COMPUTACIÓN.

.....
Ph.D. Pablo Pico Valencia

Tutor de Tesis

.....
Mgt. Manuel Nevarez

Lector 1

.....
Mgt. Homero Velastegui Izurieta

Lector 2

.....
Mgt. Homero Velastegui Izurieta

Coordinadora de la Escuela de Sistemas y Computación

AUTORÍA

Yo, **DANY DARIO PIANCHICHE AÑAPA** portador de la cédula de identidad No. **0803218189** declaro que los resultados obtenidos en la investigación que presento como informe final, previo a la obtención del título de “Ingeniero de Sistemas y Computación” son absolutamente originales, auténticos y personales.

En tal virtud, declaro que el contenido, las conclusiones y los efectos legales y académicos que se desprenden del trabajo propuesto de investigación y luego de la redacción de este documento son y serán de mi sola, exclusiva responsabilidad legal y académica.

.....

Dany Pianchiche Añapa

C.I. 0803218189

DEDICATORIA

Este trabajo de investigación está dedicado a Dios por la vida, la sabiduría y las condiciones para llevar a cabo mis estudios y poder terminarlos con éxito.

A mi familia, las personas que más amo y adoro en este mundo, a mis padres por su amor, trabajo y sacrificio en todos estos años, gracias a ellos he logrado llegar hasta aquí, por el cariño y apoyo incondicional, durante todo este proceso, por estar conmigo en todo momento gracias.

A mis amigos por apoyarme cuando más los necesito, por extender su mano en momentos difíciles y por el amor brindado cada día, cuya amistad y compañía han hecho más llevaderos los desafíos.

También a mis profesores y mentores, cuya sabiduría y guía han iluminado nuestro camino hacia el conocimiento. Que este esfuerzo dedicado a ustedes sea un testimonio de gratitud y reconocimiento por ser parte fundamental de nuestro éxito.

AGRADECIMIENTOS

En primera instancia agradezco a Dios por tenernos con salud y permitirme terminar una etapa tan importante de mi vida.

Gracias a mi madre y padre por motivarme día a día para ser una mejor persona y estar pendiente de mi educación y bienestar, por guiarme, por su apoyo incondicional y su fe en mi capacidad para cumplir con mis objetivos, por sus palabras de aliento y ánimo que me impulsan a perseverar.

A mi asesor por su orientación experta, paciencia constante y valiosos comentarios a lo largo de este proceso, para culminar con satisfacción el proyecto.

ÍNDICE

INTRODUCCIÓN.....	1
Presentación del problema	1
Planteamiento del problema.....	2
Justificación	3
Objetivos.....	4
CAPÍTULO 1: MARCO TEÓRICO	5
1.1 Bases teóricas-científicas	5
1.1.1 Sexismo	5
1.1.2 Minería de textos	6
1.1.2.1 Etapas del minado	6
1.1.3 Minería de textos aplicada en el análisis de sentimientos	8
1.1.3.1 Análisis de sentimientos usando aprendizaje automático.....	9
1.1.4 Aprendizaje automático aplicado al análisis de sentimientos	11
1.1.5 Clasificadores automáticos	13
1.2 Antecedentes	19
1.3 Fundamentación legal	22
Capítulo 2: Metodología.....	24
2.1. Delimitación espacio-temporal	24
2.2. Tipo de investigación.....	24
2.3. Métodos de investigación	24
2.4. Población y muestra.....	25
2.5. Operacionalización de variables	25
2.6. Técnicas e instrumentos de recolección de datos	26
2.7. Técnicas de procesamiento y análisis de datos	26
2.8. Normas éticas.....	27

CAPÍTULO 3: RESULTADOS	28
3.1 Diseño del sistema	28
3.1.1 Arquitectura del sistema	28
3.1.2 Dataset	29
3.1.3 Desarrollo del clasificador.....	29
3.1.4 Sistema de transformación de video a texto	32
3.2 Evaluación de los modelos	33
Capítulo 4: Discusión	36
Capítulo 5: Conclusiones y recomendaciones	37
5.1 Conclusiones	37
5.2 Recomendaciones	37
REFERENCIAS	39

ÍNDICE DE TABLAS

Tabla 1 Variables e indicadores del estudio.....	25
Tabla 2 Métricas de precisión de los modelos.....	34
Tabla 3 Resultado de pruebas.....	35

INDICE DE FIGURAS

Figura 1 Arquitectura de minería de textos	6
Figura 2 Técnicas de análisis de sentimientos.....	8
Figura 3 Arquitectura de análisis de sentimientos con aprendizaje automático.....	9
Figura 4 Naive Bayes [26].....	14
Figura 5 Regresión logística [28].	16
Figura 6 Maquina de soporte de vectores [31].	17
Figura 7 Algoritmo KNN [34].....	18
Figura 8 Árbol de decisión [37].....	19
Figura 9 Arquitectura del sistema propuesto.....	28
Figura 13 Interfaz de visual Studio Code	32
Figura 14 Resultado del sistema de transformación	33
Figura 15 Matriz confusión Árbol Decisión.....	45
Figura 16 Matriz confusión SVM.....	46
Figura 17 Matriz de Confusión Naive Bayes	46
Figura 18 Matriz de Confusión Regresión Logística.....	47
Figura 19 Matriz de Confusión K Vecinos más cercanos	47

RESUMEN

La presente investigación muestra la creación de un clasificador según su nivel de sexismo en las letras de canciones del género musical urbano. Este sistema predice de acuerdo con tres categorías siendo estas “A” apto para todo público, “B” bajo supervisión de adultos y “C” contenido para adultos. Para crear este clasificador se usó diferentes modelos de aprendizaje automático, siendo estas, Naïve Bayes, vecinos más cercanos, árbol de decisión, máquina de vectores de soporte y regresión logística. Para el entrenamiento de los modelos se creó un dataset de 479 datos, con una estratificación del 75% de los datos para entrenamiento y el 25% para prueba. El conjunto de datos incluye expresiones sexistas y no sexistas, así mismo se encuentran diferentes letras de canciones que son considerados sexistas y letras de canciones para todo público. Se entrenó cada modelo con este set de datos, obteniendo así un grado de precisión del 80% en el modelo regresión logística. Asimismo, el clasificador fue integrado con una interfaz gráfica facilitando el uso de este para cualquier usuario y un programa que pasa un video a texto realizado en Python.

Palabras claves: Inteligencia artificial, aprendizaje automático, sexismo.

ABSTRACT

The present investigation shows the creation of a classifier according to its level of sexism in the lyrics of songs of the urban musical genre. This system predicts according to three categories, these being "A" suitable for all audiences, "B" under adult supervision and "C" adult content. Different machine learning models were used to create this classifier, these being Naïve Bayes, nearest neighbors, decision tree, support vector machine and logistic regression. For the training of the models, a dataset of 479 data was created, with a stratification of 75% of the data for training and 25% for testing. The data set includes sexist and non-sexist expressions, as well as different song lyrics that are considered sexist and song lyrics for all audiences. Each model was trained with this data set, thus obtaining a degree of accuracy of 80% in the logistic regression model. Likewise, the classifier was integrated with a graphical interface facilitating its use for any user and a program that converts a video to text made in Python.

Palabras claves: Artificial intelligence, machine learning, sexism.

INTRODUCCIÓN

Presentación del problema

La minería de textos es una aplicación del procesamiento del lenguaje natural y del aprendizaje automático que permite la extracción de información relevante de documentos heterogéneos en formato de textos obtenido principalmente de comentarios de redes sociales, contenidos de páginas web, mensajes de correo electrónico, entre otros [1].

En el dominio del análisis de sentimientos, la minería de textos se ha aplicado en varias redes sociales para realizar el análisis de opiniones de los usuarios ante ciertas publicaciones. Un estudio social realizado en septiembre de 2014 presentó cómo algunas personas en Sri Lanka usaron Facebook para difundir el racismo hacia los demás. Para su detección se emplearon técnicas de minería de texto para detectar de forma automática el discurso de animosidad en cingalés [2].

Otro caso particular del uso de minería de texto fue aplicada en Twitter con el fin de extraer la subjetividad de las opiniones de las personas sobre noticias singulares en dicha red social [3]. Específicamente se determinó el sentimiento de las publicaciones de los tweets sobre noticias particulares; esto es, positivo, negativo o neutro. Siguiendo esta misma línea, un caso particular a nivel político fue el de las elecciones presidenciales austriacas de 2016, donde se extrajeron y analizaron 343645 mensajes de Twitter relacionados con las elecciones presidenciales [4]. En dicho estudio, se aplicó el análisis de sentimientos y se determinó que el ganador de la elección (Alexander Van der Bellen) envió tweets con contenido neutral; mientras que su oponente (Norbert Hofer) prefirió publicar mensajes con contenidos positivos y negativos.

Estas son algunas de las muchas aplicaciones que se le ha dado a la minería de textos en el contexto de las redes sociales. Algunas de las propuestas están dirigidas a la clasificación y categorización de textos a fin de extraer información y poder determinar no solo el significado de las opiniones; sino también, extraer las connotaciones positivas o negativas de publicaciones y opiniones en redes sociales como Facebook o Twitter, principalmente. Para ello, el uso de clasificadores automáticos es de gran importancia [5] ya que a partir de modelos de aprendizaje previamente entrenados es posible minar

opiniones en redes sociales para detectar fenómenos como: sentimientos, racismo, feminismo, homofobia, sexismo, micromachismos, entre otros. Todos ellos, fenómenos sociales que actualmente existen en redes sociales.

Planteamiento del problema

Con el crecimiento de las tecnologías también ha aumentado el número de que pueden ingresar a ella, tanto niños como adolescentes, los cuales no deben tener acceso a ciertos tipos de contenidos que son inapropiados. Los padres sienten preocupación de que sus hijos vean y escuchen cosas que no son adecuadas para su edad. Una de las actividades que más realizan los jóvenes y niños de hoy en día son escuchar canciones enmarcadas en el género urbano (reguetón). Es la música que más se escucha en la actualidad.

Las nuevas formas de crear este género han llamado mucho la atención en sus contenidos, porque en sus letras incorporan terminologías o corpus sexistas que ofenden a las mujeres o ciertas comunidades como es el caso de la comunidad intersexual (LGBTI), pudiendo llegar a ser desagradables para la sociedad en general, y especialmente para los niños.

Por citar un ejemplo de estos cantantes se tiene a Maluma que se hizo controversial por la música 4 Babys disponible en el canal de YouTube¹. Ésta es una canción que prácticamente denigra a la mujer y que contiene bastantes términos indecorosos que cualquier padre en su sano juicio no permitiría que sus hijos lo escuchen. Otro cantante que se ha hecho conocer por las letras de sus canciones, pero no precisamente por ser educativas, es Bab Bunny. En la mayoría de sus éxitos como Soy Peor, Te Boté, que se encuentra en su canal de YouTube² hablan de sexo, drogas, dinero, mujeres y fiestas. Estas canciones son actualmente un gran problema para las familias que desean inculcar valores de respeto hacia sus hijos, valores morales como el respeto, igualdad y equidad que permiten que las futuras generaciones lleguen a ser grandes personas y que aporten positivamente en la sociedad.

Se pueden utilizar diferentes técnicas de Inteligencia Artificial como lo es el aprendizaje profundo y minería de textos, para que de manera integrada ayuden a detectar

¹ <https://www.youtube.com/watch?v=OXq-JP8w5H4>

² <https://www.youtube.com/c/BadBunnyPR/videos>

contenidos específicos (i.e., sentimientos, sexismo, homofobia) no solo en audios si no también en imágenes, videos y un sinnúmero de plataformas que están expuestas a mostrarlo al público. Lo que se propone con esta investigación es analizar y determinar cuáles métodos de aprendizaje son los que tienen mayor grado de precisión para la detección de contenido sexista en letras de canciones digitales usando minería de texto. Así, esta investigación responde una interrogante en especial, esto es, ¿es posible aplicar la minería de textos para la detección automática de sexismo? Además, la investigación, ha buscado determinar ¿cuáles han sido los algoritmos de aprendizaje automático que mejor precisión (*accuracy*) han demostrado tener para el análisis de sentimientos en redes sociales? y ¿cuál de los algoritmos de aprendizaje automático se adapta a los sistemas de detección automática de contenido sexista?

Justificación

La detección de expresiones indecorosas de manera automática es importante puesto que permite analizar el sentir del público con respecto a lo que observa y escucha. En el ámbito de reproductores de audio digital, la detección automática de frases sexistas podría ser útil para realizar un filtro de las canciones y así poder determinar si es adecuado o no para el público. El hecho de que los niños y jóvenes aprenden de lo que ven y escuchan, implica que no debe ser permisible que ellos tengan acceso a contenidos no acordes a su edad.

Entonces, lo que se busca en esta investigación es experimentar con diferentes clasificadores automáticos como: Naïve Bayes [6], máquina de vectores de soporte [7], árbol de decisión [8], K-vecinos más cercanos [9], entre otros, a fin de analizar las letras de canciones e identificar contenido sexista. De esta manera, clasificadores especializados han podido ser integrados en sistemas de monitoreo o control de contenidos para niños y adolescentes, de manera que recomiende contenido musical que no atente contra la moral y los buenos valores. Así, el sistema puede ser empleado por padres de familia como mecanismo para evitar que sus hijos consuman audio digital con contenido vulgar y sexista.

Por otro lado, el desarrollo de un sistema integrado de detección de contenido sexista como el propuesto, aporta en mejorar la equidad de género, puesto que se analiza contenido que generalmente se enfoca en ver a la mujer como un objeto sexual, el

desarrollo del mismo crearía conciencia a la sociedad haciendo que tanto hombres como mujeres sean respetados de la misma manera.

Objetivos

Objetivo general

Desarrollar un sistema que analice el nivel de sexismo en la letra de canciones del género reguetón mediante el uso de técnicas de aprendizaje automático para determinar si una canción es apta o no para determinado público (niños y adolescentes).

Objetivos específicos

- a) Definir el corpus que describen acciones sexistas adaptado al vocablo ecuatoriano e implementarlo en una herramienta de procesamiento del lenguaje natural.
- b) Crear un mecanismo para transformar contenido de audio digital a formato texto.
- c) Programar un sistema inteligente que integre un modelo de detección automática de contenido sexista aplicando técnicas de minería de textos y aprendizaje automático.
- d) Evaluar el sistema propuesto en términos de exactitud empleando canciones del género urbano en español disponibles en plataformas digitales de Internet.

CAPÍTULO 1: MARCO TEÓRICO

1.1 Bases teóricas-científicas

En esta subsección se presentan las temáticas que se encuentran relacionadas con el tema de investigación permitiendo conocer y comprender de forma técnica, las bases teóricas científicas en relación con los sistemas de minería de textos aplicados en el análisis de sentimientos.

1.1.1 Sexismo

El diccionario de Oxford define el sexismo como discriminación o estereotipos contra mujeres, sobre la base del sexo. Así mismo la Real Academia Española de la lengua lo define como discriminación de personas por motivos de sexo [49]. En la sociedad la discriminación y la desigualdad sigue arraigada y cada vez se incrementa más en los medios tecnológicos [50]. En la actualidad el Internet en cierta manera naturaliza las diferencias de género y las actitudes sexistas.

Por otro lado, la misoginia y el sexismo se encuentran frecuentemente relacionados, aunque los dos términos poseen matices diferentes. En la actualidad, la definición de misoginia está en discusión. Sin embargo, la definición de misoginia más acertada implica la expresión de hostilidad y odio hacia las mujeres [51]. Por el contrario, el sexismo se entiende por cualquier forma de opresión o prejuicio contra la mujer. Es decir, el sexismo incluye misoginia, pero no es limitada por ella.

Para comprender mejor el significado a continuación se muestran algunos ejemplos de frases que tienen sexismo.

- “Eres muy sensible para ser un hombre”
- “Tiene sexo con todos, es una zorra”
- “Se viste como lesbiana”
- “¿Qué te pasa?, ¿eres gay?”
- “Sí, la ascendieron. Es que debe acostarse con alguien”.

1.1.2 Minería de textos

La minería de texto es un conjunto de "estrategias de recuperación de información no tradicional" [10]. El objetivo de estas estrategias es reducir el esfuerzo requerido de los usuarios para obtener información útil de grandes fuentes de datos de texto computarizados. Por un lado, las estrategias tradicionales de recuperación de información recuperan simultáneamente mucha información del texto. Por otro lado, las estrategias no tradicionales representan un sistema útil que debe ir más allá de la simple recuperación de información [10].

Las etapas del proceso de minería de textos incluyen la recopilación de datos para luego extraer las diferentes características que se utilizarán. Por lo cual, la minería de texto se la puede definir como un proceso de conocimiento exhaustivo en el que los usuarios interactúan con los documentos coleccionados por medio de herramientas de análisis del lenguaje natural. En esta línea, la minería de textos tiene el fin de extraer información importante de fuentes de datos a través de una exploración e identificación de patrones [11].

1.1.2.1 Etapas del minado

En términos generales, el proceso de minería de datos sigue un flujo constituido por una serie de fases [12], [13] . A continuación, se describe brevemente cada una de estas fases las cuales se deben seguir de manera secuencial como se observa en la Figura 1.

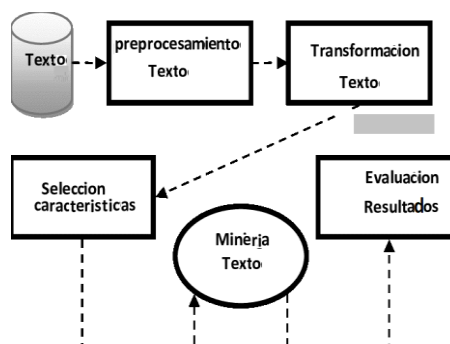


Figura 1 Arquitectura de minería de textos

- **Preprocesamiento.** El preprocesamiento tiene la función de reducir ruido lo cual facilita el proceso de clasificación de textos [14]. Se puede aplicar diferentes tipos de preprocesamiento, como eliminación de menciones, manejo de negaciones, si el texto contiene URL eliminarlos y eliminación de palabras vacías [15]. Entre estas una de las que más se usan para realizar preprocesamiento es la eliminación de palabras vacías (Stop Word Removal) [16], misma que consiste en eliminar las palabras oclusivas es decir que no tienen ningún impacto en los resultados, esto incluye eliminar preposiciones, artículos como “a”, “una” y “la”. Las palabras vacías no contienen ni afectan los sentimientos por lo que eliminarlas refina y ayuda en gran medida el proceso de minería de textos [17].
- **Selección de características.** Las técnicas más destacadas para la selección de características son frecuencia de término (TF), característica (FP), y frecuencia de término-frecuencia de término inverso (TF-IDF) [18]. TF es la cantidad de veces que el documento presenta una característica, FP comprueba si una característica aparece o no en el documento y el TF-IDF se utiliza para medir la importancia de una palabra en el documento, aumentando el valor de la palabra proporcionalmente a la cantidad de veces que aparezca la palabra [16].
- **Minería de textos.** Una vez completada la selección de características, el siguiente paso es hacer el modelo de entrenamiento para la minería de textos. Esto, para diferentes tipos de requisitos de aplicación, se utilizan diferentes tipos de modelos, modelos tradicionales de aprendizaje automático supervisado y no supervisados como: vecinos más cercanos, máquina de soporte de vectores, Naïve Bayes, árbol de decesiones y k-media, entre otros [19].
- **Evaluación de resultados.** Esta es una fase importante para que el modelo entrenado tenga una mejor capacidad de generalización del corpus. Los índices de evaluación del modelo incluyen la tasa de error, precisión, tasa de recuperación, entre otros [19]. La fórmula de cálculo más importante de la tasa de precisión es la descrita en la ecuación (1).

$$P(T) = TP / (TP + FP) \quad (1)$$

La tasa de precisión es para los resultados de predicción e indica cuántas de las muestras que se usaron en la fase de entrenamiento son muestras reales. En la ecuación anterior TP y FP representan el número de muestras correctas e incorrectas y P(T) es la tasa de precisión del modelo.

1.1.3 Minería de textos aplicada en el análisis de sentimientos

El análisis de sentimientos o minería de opiniones es un proceso de comprensión, extracción y procesamiento de datos textuales automáticamente para obtener información sobre los sentimientos contenidos en una oración de opinión. El análisis de sentimientos se realiza para identificar tendencias de opiniones sobre un problema u objeto particular; esto es, determinar opiniones negativas o positivas [20].

Hay varios enfoques para realizar el análisis de sentimientos, entre estas el enfoque basado en aprendizaje automático el cual utiliza varios algoritmos de supervisados para clasificar los datos. Por otro lado, el enfoque basado en léxico que utiliza un diccionario que contiene palabras positivas y negativas para determinar la polaridad del sentimiento y como última técnica se encuentra el enfoque híbrido el cual utiliza la combinación de los dos enfoques [21], como se observa en la Figura 2.




Figura 2 Técnicas de análisis de sentimientos.

- **Enfoque basado en aprendizaje automático.** El aprendizaje automático para el análisis de sentimientos comienza con la recopilación de datos, para posteriormente manejarse por diversas técnicas de procesamiento del lenguaje natural y finalmente se utiliza el aprendizaje automático para realizar pruebas con los nuevos datos, en la siguiente sección se explica con más detalle este enfoque.

- **Enfoque basado en léxico.** Esta técnica tiene como objetivo encontrar el léxico de opinión para calcular el sentimiento para un texto dado. Es decir, cuenta el número de palabras positivas y negativas del texto, lo que quiere decir que, si el texto consta de más palabras positivas, se le da una puntuación positiva, en caso contrario se le asigna una puntuación negativa. Por otro lado, si el resultado consta del mismo número de palabras positivas y negativas se le da una puntuación de neutral.
- **Enfoque híbrido.** Para mejorar el rendimiento de la clasificación de sentimientos, pocas técnicas de estudio proponen la combinación de las técnicas de aprendizaje automático y basado en léxico [21]. La combinación de estas técnicas ha demostrado que mejora la precisión [22]. El enfoque basado en el léxico tiene un alto rendimiento en precisión y uso de memoria baja por lo que se mejora los resultados en comparación con las otras técnicas.

1.1.3.1 Análisis de sentimientos usando aprendizaje automático

El análisis de sentimientos se lleva a cabo utilizando una gran variedad de técnicas. No obstante, los principales métodos que se utilizan en la actualidad se basan principalmente en el aprendizaje automático. En la Figura 3 se muestra la arquitectura básica del análisis de sentimientos de aprendizaje automático.

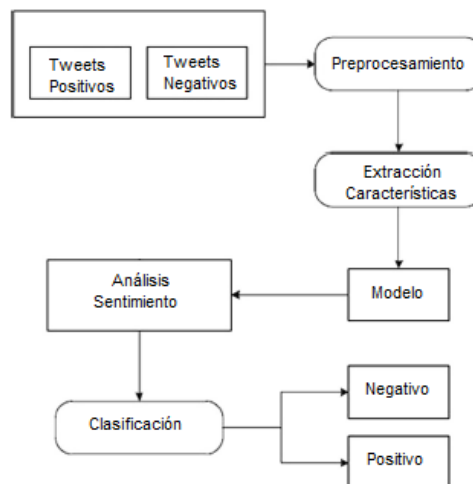


Figura 3 Arquitectura de análisis de sentimientos con aprendizaje automático.

El análisis de sentimientos aplicando aprendizaje automático empieza con la compilación de un conjunto de datos que contiene tweets etiquetados como se observa en la Figura 3, posteriormente los datos se manejan utilizando las herramientas del procesamiento del lenguaje natural que se han especificado anteriormente. Luego se extraen las características que son más importantes para el análisis de sentimientos y, finalmente, se entrena y se prueba el modelo clasificador con datos nuevos [21]. A continuación, se describen los pasos con más detalle:

- **Recopilación de datos.** Se recopilan los tweets utilizando la API de Twitter es decir la recopilación de datos. La red social puede variar sin cambiar el proceso como tal.
- **Preprocesamiento.** La parte del procesamiento de datos en un algoritmo de aprendizaje automático puede tener un impacto significativo en cuanto al rendimiento. Y para llevar a cabo el preprocesamiento se siguen los siguientes pasos.
 - **Conversión de mayúsculas y minúsculas.** Todas las palabras se convierten en minúsculas o mayúsculas para eliminar posibles diferencias entre “Análisis” y “análisis” para su posterior procesamiento.
 - **Eliminación de palabras vacías.** Eliminación de palabras vacías como “uno”, “el”, tiene entre otros, que no tienen ningún significado.
 - **Eliminación de signos de puntuación.** Como las comas, puntos, dos puntos, por lo que no tienen ningún significado para el análisis de sentimientos.
 - **Derivación.** La derivación por lo general se refiere al proceso que corta los extremos de las palabras para eliminar afijos derivacionales.

- **Lematización.** Se ocupa de la eliminación de terminaciones flexivas y para devolver la base o forma de diccionario de una palabra, que se conoce como lema.
- **Corrección ortográfica:** Se realiza basándose en la selección automática de la palabra más probable.
- **Extracción de características.** Luego de procesar los tweets, se extraen las características relevantes para el análisis de sentimientos. Entre estas características están:
 - **Etiquetado del discurso.** Las palabras se etiquetan con sus respectivas partes del texto para extraer adjetivos, sustantivos y verbos que logran aportar significado al sentimiento.
 - **Palabras o frases.** Palabras o frases que expresan opinión del texto.
 - **Negación.** Presencia de palabras como “no”, “Ninguno” pueden revertir el sentimiento de todo por ejemplo “no es bueno”.
- **Clasificador automático.** Después de realizar los pasos anteriores, se elige un modelo clasificador de aprendizaje automático para el análisis de sentimientos. Los datos de entrenamiento se usan para entrenar al clasificador y su rendimiento se mide en base a sus datos de prueba. Y finalmente, se realiza el análisis de sentimientos con nuevos datos y realizar predicciones.

1.1.4 Aprendizaje automático aplicado al análisis de sentimientos

El aprendizaje automático es una de las técnicas de la Inteligencia Artificial, ampliamente usadas para hacer que una máquina aprenda a partir de grandes cantidades de datos masivos [16]. Para llevar a cabo las tareas de aprendizaje por parte de las máquinas se emplean generalmente algoritmos que permiten predecir datos a través de regresiones, clasificadores y algoritmos de agrupamiento que se resumen en algoritmos de aprendizaje supervisado, no supervisado y por refuerzo [23].

A continuación, se describe brevemente el alcance de los 3 principales tipos de aprendizaje:

- **Aprendizaje supervisado.** Son los procedimientos más simples de ejecutar y comprender, constituyen el método que clasifica datos etiquetados en base a un patrón compartido. El propósito consiste en utilizar datos de entrenamiento, donde X representa las variables que anticipan una salida específica, Y , estas variables pueden ser numéricas en el contexto de la regresión o descriptivas en situaciones de clasificación.
 - Los **algoritmos de clasificación** se usan cuando el resultado que se busca es una etiqueta discreta. Es decir, se tiene una clasificación binaria, solo se elige entre dos etiquetas, así mismo para la clasificación de múltiples etiquetas.
 - Por otro lado, los **algoritmos de regresión** son adecuados para predecir valores continuos. Es decir, que las respuestas a las interrogantes se representan mediante cantidades flexibles en función de las entradas del modelo, y no solo limitarse a un conjunto de posibles etiquetas. Consiste en un modelo para aproximar la relación de dependencia entre una variable dependiente, las variables y un término independientes B .

- **Aprendizaje no supervisado.** Los datos Los datos se estructuran de manera que su configuración pueda ser descrita; esto involucra la formación de agrupaciones de datos en clústeres o la búsqueda de diversas formas para analizar información compleja, con el fin de simplificarla y ordenarla. A diferencia del aprendizaje supervisado, no se dispone de conocimiento previo ni etiquetas de salida. Solo se cuenta con la variable X , sin la presencia de las variables X e Y . El propósito del aprendizaje no supervisado radica en distribuir los datos con el propósito de adquirir un mayor entendimiento sobre ellos. En términos generales, estos métodos pueden ser clasificados en algoritmos de agrupamiento y asociación.

- **Aprendizaje por refuerzo.** En este caso son problemas no supervisados que reciben refuerzos o realimentaciones. Se sustituye la información supervisada (Y)

por información de tipo acción/reacción. Tiene por objetivo aprender a mapear situaciones de acciones para maximizar funciones de resultado. En estos problemas el modelo aprende por prueba y error en un ambiente dinámico e incierto. En cada interacción el agente recibe como un indicador de estado actual y selecciona una determinada acción que maximice una función de refuerzo o recompensa a largo plazo.

1.1.5 Clasificadores automáticos

Uno de los tipos de algoritmos usados en aprendizaje automático son los clasificadores. En este contexto, consiste en utilizar inteligencia artificial en un conjunto de elementos para ordenarlos por clases o categorías. A continuación, se describen algoritmos de los principales clasificadores más populares y usados en la actualidad para clasificar patrones.

Naïve Bayes. Naïve Baye (NB) es un clasificador lineal, es un método de aprendizaje automático simple basado en estadísticas, las decisiones se toman en función de ausencia o presencia de determinadas características [24]. Así mismo es un clasificador probabilístico que aplica el Teorema de Bayes con presunción de independencia entre características.

Suponiendo un conjunto de n documentos $D = \{d1, d2, \dots, dn\}$, las cuales pertenecen a una de las m clases $C = \{c1, c2, \dots, cm\}$. La probabilidad de clasificar un documento D en la clase C se calcula mediante la siguiente ecuación (2):

$$P(C|D) = \frac{P(C)P(D|C)}{P(D)} \quad (2)$$

Naïve Bayes asume que una palabra o un término en un documento d , existe independientemente en el documento d con clase c . Por tanto, la ecuación (3) se convierte en:

$$P(c|d) a P(c) \pi_{k=1}^{n_d} [P(w_{k|c})]^{t_k} \quad (3)$$

Donde α representa proporcionalidad, nd representa el número de palabras únicas en el documento d y tk representa la frecuencia de la palabra wk .

El clasificador Naïve Bayes combina el modelo de probabilidad derivado con una regla de decisión. Es decir, se selecciona el valor, que tiene la mayor probabilidad [17]. Este enfoque se conoce como el “Máximo a Posteriori”. Por otro lado, este modelo funciona bastante correcto en situaciones del mundo real como la clasificación de documentos y el filtrado de spam, siendo estos extremadamente rápidos en comparación con métodos más sofisticados [25]. A continuación, con la ayuda de la Figura 4 se analiza los problemas lineales (A) y no lineales (B).




Figura 4 Naive Bayes [26].

Las muestras aleatorias para dos clases diferentes se muestran en dos colores y las líneas de puntos indican los límites de clase que los clasificadores intentan aproximar calculando los límites de decisión. Un problema no lineal (B) sería un caso en el que los clasificadores lineales, como Bayes ingenuo, no serían adecuados ya que las clases no son linealmente separables. En tal escenario, deberían preferirse los clasificadores no lineales.

Regresión Logística. El modelo de regresión logística es un clasificador que se centra en el problema de clasificación binaria así como manejar problemas de clasificación múltiple [13]. La regresión logística asigna cualquier valor de entrada al $[0,1]$ y obtiene un valor predicho en regresión lineal. Entonces, mapear este valor a la función sigmoide y utilizar

la predicción valor como la variable del eje “x” y el eje “y” como probabilidad. La fórmula de regresión logística es la de la ecuación (4).

$$g(z) = \frac{1}{1+e^{-z}} \quad (4)$$

Y la función de predicción es la descrita en la ecuación (5):


$$h\theta(x) = g(\theta^T x) = \frac{1}{1+e^{-\theta^T x}} \quad (5)$$

El valor de θ representa la probabilidad de que $h\theta(x)$ es 1. Por lo tanto, la probabilidad de que el resultado de clasificación de entrada x es de categoría 1 y categoría 0 es la descrita en la ecuación (6) y (7):

$$P(Y = 1|x; \theta) = h\theta(x) \quad (6)$$

$$P(Y = 0|x; \theta) = 1 - h\theta(x) \quad (7)$$

Por medio de los resultados se puede dar a los diferentes puntos un cierto peso para medir la importancia que tiene en la clasificación. Mientras se entrena el modelo, algunas características pueden ser menos relevantes que otras, lo que lleva al ajuste de peso para obtener mejores resultados [27]. En la Figura 5 se muestra la función sigmoidea de una variable x :



La función sigmoidea tiene valores muy cercanos a 0 y 1 en la mayor parte de su dominio, es decir esto lo hace apto para aplicarlo en métodos de clasificación.

Máquina de vectores de soporte (SVM). La máquina de vectores de soporte (SVM) es un método de aprendizaje automático supervisado. SVM usa datos de entrenamiento para separar y construir un hiperplano de margen máximo que pueda usarse para la clasificación [29]. A continuación, en la ecuación (8), se muestra la función que lo define:

$$f(x) = w \cdot x + b, w \in R^d, b \in R \quad (8)$$

Donde d es la dimensionalidad del espacio de datos, w es el factor de peso, denota sesgo de la función, y x es el vector de datos de entrenamiento.

Las SVM se utilizan para mapear espacios de muestra en espacios de características con una dimensión alta (o incluso infinita) a través del mapeo no lineal, transformando los problemas que no son linealmente separables en el espacio muestral original, en problemas linealmente separables en el espacio de características [30]. El concepto central detrás de las Máquinas de Soporte Vectorial (SVM) es descubrir un hiperplano de margen máximo que logre una separación óptima entre las clases en el conjunto de datos, tal como se ilustra en la Figura 6. Los vectores de soporte corresponden a los puntos de datos que se hallan más cercanos al hiperplano; estos puntos desempeñan un papel crucial al definir de manera más precisa la línea de división al calcular los márgenes. Los puntos son esenciales para realizar la tarea de clasificaciones.




Figura 6 Máquina de soporte de vectores [31].

K-vecinos más cercanos (K-nn). El modelo k vecinos más cercanos es un algoritmo sencillo que se usa tanto para problemas de regresión y clasificación [32]. El algoritmo K-nn clasifica nuevas clases basados en medidas de similitud, así mismo se lo utiliza para estimación de estadística y reconocimiento de patrones.

El algoritmo se clasifica por mayoría de votos de sus vecinos, y el dato se asigna a la clase más común entre su vecino más cercano k el cual es medido por una función de distancia. Si $k=1$, en este caso el dato se le asigna a la clase de su vecino más cercano. Para calcular la distancia para las variables continuas son de tres tipos Euclidiana (9), Manhattan (10) y Minkowski (11) [33].

$$\sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (9)$$

$$\sum_{i=1}^k |x_i - y_i| \quad (10)$$

$$(\sum_{i=1}^k (|x_i - y_i|)^p)^{1/p} \quad (11)$$

Para casos de variables categóricas, se debe utilizar la distancia de Haming, ecuación (12). Así mismo, se estandariza las variables entre 0 y 1 cuando hay una mezcla de variables numéricas y categóricas en el conjunto de datos que se trabaje.

$$D_H = \sum_{i=1}^k |x_i - y_i| \quad (12)$$

La mejor manera de elegir el valor óptimo para k es en primer lugar inspeccionar los datos. Por lo general un valor de k en gran volumen es más preciso ya que reduce el ruido en general.

Con el propósito de mejorar la comprensión del algoritmo, se emplea la Figura 7 como una representación visual. En esta ilustración, el objetivo es clasificar un punto nuevo, denominado X, dentro de dos categorías posibles: roja o azul. En este escenario, se opta por un valor de $k=3$. El algoritmo K-nn inicia el proceso calculando la distancia entre el punto X y todos los demás puntos en el conjunto de datos. A continuación, identifica los tres puntos más cercanos a X en términos de menor distancia, tal como se muestra en la Figura 7.




Figura 7 Algoritmo KNN [34].

La etapa final implica asignar el punto nuevo a la categoría que es mayoritaria entre los tres puntos más próximos. En la figura se evidencia que dos de los tres puntos de mayor cercanía corresponden a la categoría "rojo", mientras que solo uno de ellos pertenece a la categoría "azul". Como resultado, el punto nuevo X se clasificará como "rojo".

Árbol de decisión (DT). El algoritmo árbol de decisión es un modelo que representa una clase alternativa de un algoritmo de clasificación. La estructura de un DT se asemeja a un

árbol, donde cada nodo que tiene es un atributo de prueba, cada rama representa el resultado de la prueba, y el nodo hoja representa la clase [35].

Así mismo, el árbol de decisiones es un modelo de predicción que utiliza una estructura de árbol o una estructura jerárquica. El concepto de árbol de decisión es transformar datos en árboles de decisión y reglas de decisión. El principal valor de emplear un árbol de decisiones reside en su capacidad para simplificar procesos complejos de toma de decisiones, lo cual facilita a los responsables de tomar decisiones comprender de manera la resolución del problema. [36].

Se utiliza el árbol de decisión para los problemas que se tiene características de entrada y de destino continuas, pero también para salidas categóricas. La idea principal de estos modelos es encontrar las características descriptivas que contienen la mayor cantidad de información de las características de salida, y luego dividir el conjunto de datos a lo largo de todos los valores de estas características, de modo que el resultado de salida para los sets de datos sean los más acertados posibles.

Un árbol de decisión contiene un nodo raíz, nodos interiores y nodos hoja que están conectadas por ramas como se visualiza en la Figura 8.

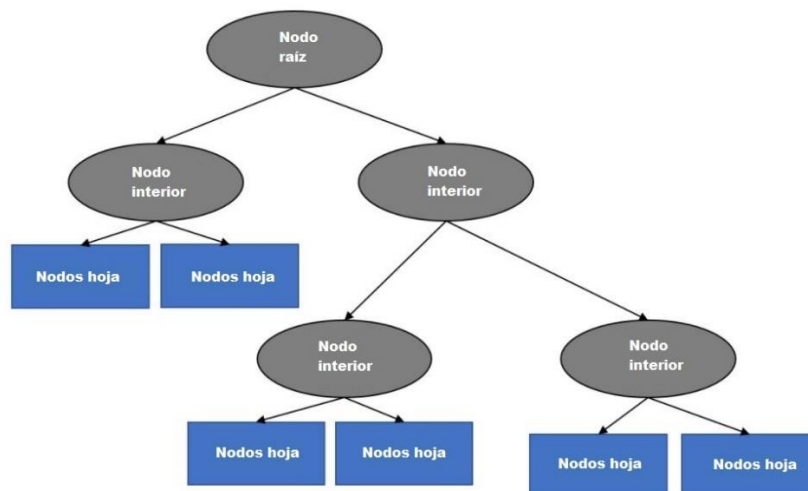


Figura 8 Árbol de decisión [37].

1.2 Antecedentes

Se ha realizado varios estudios respecto al análisis de sentimientos y discursos de odio en diferentes redes sociales a lo largo de estos últimos años (2018-2022). A continuación, se presenta un análisis de los trabajos realizados por las diferentes técnicas de minería de textos, aprendizaje automático y aprendizaje profundo, siendo las técnicas que más se manejan para realizar estos procesos de los estudios anteriormente mencionados.

Por lo general se encuentran variedad de textos en las redes sociales y el uso de la inteligencia artificial ha ayudado en gran medida para detectar el discurso de odio para el análisis de sentimientos. En este campo la Universidad de Lin Jiang y la Universidad Yoshimi Suzuki de Yamanashi [52] realizaron varias comparaciones usando distintas proporciones de datos sacados de la red social Twitter con diferentes técnicas al mismo tiempo. Como resultado, el estudio evidenció que el aprendizaje automático puede llegar a tener un buen rendimiento cuando los datos son pequeños. Sin embargo, mejores resultados se obtuvieron en el estudio, al implementar aprendizaje profundo cuando los datos eran mayores. Además, se afirmó que el uso del modelo de red neuronal recurrente (RNN) obtuvo mejores resultados en comparación con otros métodos que se utilizaron como es el caso de regresión logística y máquina de soporte de vectores.

Siguiendo la misma línea, Ziqi Zhang, David Robinson y Jonathan Tepper [53] utilizaron una red convolucional (CNN) con unidad recurrente cerrada (GRU), combinado con incrustaciones de palabras. Para poder detectar los discursos de odio en la red social Twitter llevando a cabo una evaluación del método en la colección más grande de conjunto de datos que estaban disponibles hasta 2018. Los investigadores obtuvieron como resultado que su modelo propuesto logró el puntaje de F1 más alto que es el valor combinado de las medidas de precisión y recall. Al final, el estudio demostró que la combinación del modelo de red neuronal profunda CNN y GRU mejoran empíricamente la precisión de la clasificación.

En lo relacionado a la técnica de minería de textos, Risul Islam Rasel, Nasrin Sultana, Phayung Meesad [54] realizaron un estudio con el fin de filtrar los comentarios que ellos denominan cyber agresivos en tres categorías: discurso de odio, discurso ofensivo o ninguno de los dos. Utilizaron para ello minería de texto y un enfoque de aprendizaje automático. En el estudio, se recopiló los datos de texto de la red social del sitio web *Data World*. Posteriormente, se usaron algunas técnicas de extracción de características como N-gram y frecuencia de término – frecuencia inversa de documento (TF-IDF) las cuales sirvieron para preparar las entradas para los clasificadores de aprendizaje automático

como fueron: bosque aleatorio con 93% de precisión, regresión logística 86% de precisión y la máquina de vectores de soporte 72% de precisión; obteniendo como resultado que el modelo que los autores propusieron puede clasificar los comentarios agresivos con más del 93% de precisión. Así mismo con las otras técnicas utilizadas, el bosque aleatorio excede ligeramente la regresión logística, pero tiene una calidad de rendimiento muy alto en cuanto a la máquina de vectores de soporte. Pero el hallazgo más significativo del estudio fue la combinación ajustada de TF-IDF, LSA (análisis semántico latente) que en conjunto con el análisis de similitud de coseno llegaron a producir un vector de características optimizado para la clasificación de los comentarios.

Por otro lado, en estos últimos tiempos se ha expandido el esfuerzo por obtener diversas informaciones de la gran cantidad de servicios de redes sociales, los datos grandes comprenden oraciones clasificadas como los datos no estructurados, por lo cual en [55] proponen un sistema que pueda extraer información de sentimientos humanos de grandes cantidades de datos no estructurados, usando el algoritmo Naïve Bayes y técnicas del procesamiento del lenguaje natural (PNL) para preprocesar el contenido de la información. Así mismo, se analizó la efectividad del método propuesto a través de varios experimentos. Los resultados experimentales mostraron que el método de aprendizaje automático que utilizaba el algoritmo Naïve Bayes proporcionaba una precisión del 63.5%, que de acuerdo con el análisis de velocidad de procesamiento de datos el rendimiento de procesamiento fue aproximadamente 5.4 veces mayor que el método de PNL.

Finalmente, en otro campo, en la línea de la industria de televisión, que es uno de los medios de comunicación más utilizados en indonesia como indican los autores Dani Rohpandi, Evi Dewi y Fityan Atqia [12], se ha provocado que cada estación compita para presentar diversos tipos de programas. La industria televisiva usa la red social Twitter como medio de publicación del mismo, también es un portavoz de la crítica y el asesoramiento público sobre los programas que se emiten. Con este fin los autores proponen analizar los datos de los tweets, mediante una aplicación usando el algoritmo Naïve Bayes para poder producir información sobre la valoración del sentimiento público respecto a los programas de televisión. Esta aplicación se diseñó usando el lenguaje Python y PHP. Obteniendo como resultado una precisión del 91.67%.

Este último antecedente, aunque no está enmarcado en la línea de investigación del proyecto, es importante resaltar su variedad de uso en diferentes áreas ayudando a mejorar

la productividad y los servicios que estos ofrecen, como es el caso de la industria televisiva, el área de salud, en la política, en el mercado entre otros.

1.3 Fundamentación legal

Dentro de las bases legales que deben tomarse en cuenta para el presente proyecto se estipulan las siguientes: la Constitución de la República del Ecuador [56] y la ley Orgánica de Comunicación [57].

En la Constitución de la República del Ecuador se menciona en el artículo 16 que todas las personas tienen derecho ya sea de forma individual o colectiva el acceso universal a las tecnologías de información y comunicación, además en el artículo 19 se menciona que la ley solo regulará la prevalencia de contenidos con fines educativos, informativos y culturales en la propagación de los medios de comunicación [56]. Con el presente proyecto de investigación se busca determinar si un contenido digital de audio contiene un nivel de aceptación para el público general, lo cual ayudaría a los medios de comunicación a que no se propaguen contenidos inadecuados.

Así mismo en el artículo 385 de la Constitución de la República del Ecuador se indica que el sistema nacional de ciencia, tecnología, innovación y saberes ancestrales, en el marco del respeto al ambiente, la naturaleza, la vida, las culturas y la soberanía, tendrá como finalidad: Desarrollar tecnologías e innovaciones que impulsen la producción nacional, eleven la eficiencia y productividad, mejoren la calidad de vida y contribuyan a la realización del buen vivir [56]. Se ha considerado este artículo porque en la investigación se realiza un sistema tecnológico que ayuda a evitar sentimientos xenofóbicos, racistas y que denigren a las personas, contribuyendo de esta manera al buen vivir.

En cuanto a la propiedad intelectual se toma en cuenta el artículo 322 que se reconoce la propiedad intelectual de acuerdo con las condiciones que señale la ley. Se prohíbe toda forma de apropiación de conocimientos, en el ámbito de las ciencias, tecnologías y saberes ancestrales [56]. De manera que en el estudio se respetará la autoría de artículos y códigos disponibles que han servido de base para realizar el estudio.

Finalmente, se ha considerado necesario tomar en cuenta a la ley Orgánica de Comunicación el artículo 76 donde se menciona que los sistemas de audio y video deben

estar previamente calificados por el Consejo de Regulación y Desarrollo de la Información y Comunicación para tal efecto, considerando la calidad de sus contenidos y programación, siempre que satisfagan las condiciones técnicas que establezca la autoridad de telecomunicaciones [57].

El sistema de investigación desarrollado colaboraría conjuntamente al Consejo de Regulación y Desarrollo a facilitar la calificación de los contenidos de audio para que estos sean de calidad para todo el público.

Capítulo 2: Metodología

2.1. Delimitación espacio-temporal

El presente proyecto de investigación no cuenta con una delimitación espacial puesto que es una investigación necesariamente experimental y puede llevarse a cabo en cualquier institución, sin embargo, se precisó los estudios que se han desarrollado a nivel mundial y se tomó como base la realidad y los modismos lingüísticos de Ecuador. En cuanto a la delimitación temporal, el estudio se planteó en el último trimestre del año 2020. Así mismo, la culminación de la investigación se efectuó en el primer semestre del año 2023.

2.2. Tipo de investigación

La investigación es mixta dado que es de tipo cualitativa y cuantitativa, puesto que en la primera parte se analiza las técnicas más usadas basados en los datos y resultados de autores que ya han implementado las técnicas de aprendizaje en análisis de sentimientos en redes sociales. En la segunda parte de la investigación al momento de analizar cada una de las técnicas de aprendizaje automático se experimentó con cada una de ellas probando así la precisión y la efectividad que tiene cada uno en el mismo problema, es ahí cuando entra la parte cuantitativa ya que se evaluó estas métricas. Es decir, en esta parte se trabajó con datos que se puede analizar y medir para determinar que técnica de las que se probó es la óptima.

2.3. Métodos de investigación

El presente proyecto es de tipo experimental puesto que se basó en la manipulación de varias técnicas de aprendizaje en el cual se realizó diferentes pruebas que ayudaron a determinar el mejor ajuste o configuración de los algoritmos. Así mismo, la elaboración de este proyecto tuvo como base el método inductivo y deductivo para ayudar a identificar el mejor clasificador para determinar sexismo.

2.4. Población y muestra

Para esta investigación se consideró como población las técnicas de aprendizaje más comunes para implementar sistemas de minería de texto basadas en aprendizaje automático, ampliamente usadas para realizar análisis de sentimientos. Dentro del aprendizaje automático, hay un sin número de algoritmos. Sin embargo, en base a las experiencias de otros investigadores y a su uso extendido en los estudios analizados, se emplearon cinco algoritmos de aprendizaje máquina: Naïve Bayes, regresión logística, máquina de vectores de soporte, k-vecinos y árbol de decisión [27]. Asimismo, para realizar el análisis del sistema, se utilizaron las canciones de los 6 cantantes del género urbano más populares del año 2020 de acuerdo con la página (okdiario.com).

2.5. Operacionalización de variables

A continuación, en la Tabla 1, se muestran las variables e indicadores que se investigó respecto al uso de los algoritmos de aprendizaje automático para el análisis de sexismo. Las variables son descritas a continuación para que sea más entendible para el lector:

Tabla 1 Variables e indicadores del estudio.

Variables	Indicadores	Descripción	Tipo	Entidades
Precisión. Precisión de los modelos que se utilizó evaluándolos con diferentes parámetros como el nivel de precisión, exactitud y por medio de puntuación f1.	Métrica de precisión	Mide la calidad del modelo de aprendizaje automático.	Cuantitativa	Modelo predictivo
	Métrica de exactitud	Mide el porcentaje de casos que el modelo ha acertado.	Cuantitativa	
Rendimiento. Desempeño de los modelos utilizados en la investigación con indicadores como el tiempo de entrenamiento, de	Tiempo de entrenamiento	Tiempo que toma el modelo en realizar el entrenamiento de los datos.	Cuantitativa	Modelo predictivo. Sistema integrado propuesto
	Tiempo de prueba	Tiempo que toma el modelo en realizar el entrenamiento de la prueba de los datos previamente entrenados.	Cuantitativa	

prueba y el tiempo de respuesta con el usuario	Tiempo de respuesta al usuario	Tiempo que toma en mostrar los resultados obtenidos al usuario.	Cuantitativa	
Usabilidad. Cuán fácil es usar el sistema	Efectividad	Porcentaje de éxito de los modelos que alcanzaron de forma correcta los resultados.	Cualitativa	Usuarios
	Eficiencia	Tiempo medio que tomó a los modelos para completar y obtener el resultado.	Cualitativa	
	Satisfacción	Experiencia del usuario con los modelos.	Cualitativa	

2.6. Técnicas e instrumentos de recolección de datos

En la presente investigación se optó por la técnica de experimento el cual permite obtener datos de las métricas del clasificador entrenado. En el experimento se aplicó varios algoritmos supervisados para desarrollar los clasificadores. Se cambiaron los principales argumentos de dichos algoritmos para determinar la mejor configuración del clasificador pen la detección de sexismo. Se empleó como instrumento las métricas de la librería sklearn de Python para determinar la eficacia del modelo de clasificación de sexismo desarrollado.

2.7. Técnicas de procesamiento y análisis de datos

Las técnicas de análisis de datos que se usó fueron las siguientes:

- **Estadística:** Permite realizar un mejor análisis de los datos mostrándonos sus respectivas observaciones. Varios de los algoritmos que implementaron los clasificadores emplearon medidas de tendencia central y modelos probabilísticos.
- **Matriz de confusión:** Con esta técnica se evalúa el rendimiento del modelo de clasificación. Así mismo, se visualiza el número de predicciones correctas e incorrectas desglosándose por cada clase. En la matriz se analizaron los siguientes elementos:
 - **Verdadero Positivo.** El valor real es positivo y la prueba predice que también es positivo.

- **Verdadero Negativo.** El valor real es negativo y la prueba predice que también es negativo.
- **Falso Negativo.** El valor real es positivo y la prueba predice que es negativo.
- **Falso positivo.** El valor real es negativo y la prueba predice que es positiva.

2.8. Normas éticas

El presente proyecto se realizó de acuerdo a los lineamientos establecidos en el Reglamento de Grados de la Pontificia Universidad Católica del Ecuador Sede Esmeraldas. Así mismo, respecto a los derechos del autor se citaron de manera correcta dándole el reconocimiento que se merecen por los conceptos e ideas de los artículos utilizados para la elaboración del proyecto. A su vez se utilizó software libre para realizar la experimentación planteada en el estudio, esto con el fin de no caer en piratería.

CAPÍTULO 3: RESULTADOS

En este capítulo se describen los resultados obtenidos durante la investigación. Para desarrollar el proyecto se utilizó diferentes modelos de aprendizaje automático con el fin de analizar sexismo en las letras de canciones, el cual en el apartado del marco teórico se describe que acciones determinan sexismo, así mismo se implementó un sistema de transformación de video a texto como complemento del sistema, para luego finalizar evaluando cada uno de los modelos que se utilizó para desarrollar el sistema.

3.1 Diseño del sistema

3.1.1 Arquitectura del sistema

La arquitectura propuesta se encuentra basada en la del sistema de análisis de sentimientos en Twitter antes mencionada en el marco teórico, con diferencias en que el set de dato (dataset) fue realizado de forma manual, así mismo, una vez el sistema haya pasado por la etapa del preprocesamiento de datos y por el entrenamiento de los modelos el usuario es quien debe proporcionar la letra de la canción al sistema para realizar las pruebas y determinar que grado de sexismo posee la letra de la canción.

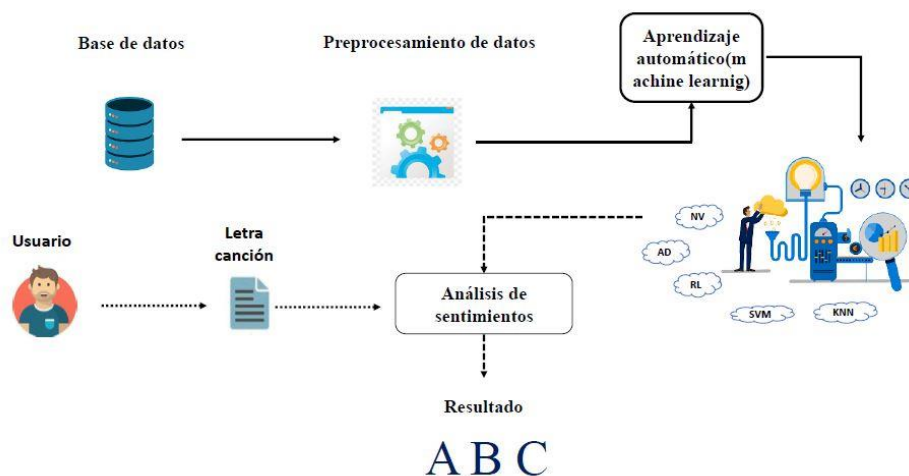


Figura 9 Arquitectura del sistema propuesto.

3.1.2 Dataset

Para la elaboración de la base de datos se usó como referencia algunas plataformas de reproducción de músicas famosas como deezer o Spotify, siendo estas las más conocidas a nivel mundial, con el objetivo de identificar qué contenidos de músicas son aptas para determinados públicos. Esto, gracias a sus listas de reproducciones conocidas como playlist que ayudan al usuario a elegir el contenido adecuado para cada edad. Se creó un dataset con 717 datos que están etiquetados en tres categorías 1, 2 y 3, siendo 1 equivalente a la categoría A, que significa apto para todo público, 2 que equivale a la categoría B, que significa bajo supervisión de un adulto y 3 que equivale a la categoría C, que significa contenido para mayor de edad o contenido para adultos, el mismo que se encuentra en la siguiente dirección.³ Para esta clasificación se usó como referencia el artículo 65 de la ley Orgánica de Comunicación de Ecuador [58].

3.1.3 Desarrollo del clasificador

Para realizar este sistema se usó el lenguaje de programación Python junto con Jupyter Notebook que es un entorno de trabajo interactivo que permite ejecutar códigos línea por línea facilitando encontrar posibles errores de código.

Uno de los primeros pasos en importar la base de datos con una configuración de separación por coma, en donde la primera columna se tiene el nombre de categ y la segunda columna con nombre txt, como se puede visualizar en la Figura 10 que es código que se usa para importar.

```
#importamos la base de datos
df= pd.read_csv("datos.txt", sep=',', names=['categ','txt'], encoding='latin-1')
```

Figura 10 Carga dataset

³ <https://github.com/DanyDr15/SistemaTesis/blob/master/Programa/datos.txt>

Para entrenar los modelos de aprendizaje automático se usó el 75% de los datos para entrenamiento y el otro 25% para test. Se procede a importar las librerías necesarias para utilizar los algoritmos requeridos y entrenarlos.

```
X_train, X_test, y_train, y_test = train_test_split(X, y, train_size=0.75, random_state=0)

from sklearn import tree
from sklearn.tree import DecisionTreeClassifier

clf=DecisionTreeClassifier()
clf.fit(X_train, y_train)
```

Figura 11 Entrenamiento de los modelos

Para probar el resultado se usó la letra de la canción del grupo CNCO con la canción “quisiera” que son conocidos por hacer canciones de reguetón aptas para todo público, A continuación, se proporciona la letra de la canción con el que se realizó la ejecución del sistema.

*Quisiera tenerte en cada primavera
Poder amarte a mi manera
Desvelarme la noche entera
Cuidar tus sueños así quisiera
Obsequiarte cada segundo
Y a su guion borrar un punto
Para añadirme en él
Y así por siempre estar juntos
Cómo explicarte lo que siento
Me estoy enloqueciendo
El doctor me recetó
Un poquito de tu afecto y no estás
Eres la cura de mi enfermedad
El caso parece de gravedad
Y venga mi princesa que el tiempo no regresa
Y yo por ti pongo el mundo de cabeza
Rosas, chocolate quiero regalarte
Un millón de besos tengo para darte*

*Y si te vas
Quien me dará
Todo lo que siempre soñé
Quien le dirá al corazón
Que jamás nunca te tendré
Quisiera tenerte en cada primavera
Poder amarte a mi manera
Desvelarme la noche entera
Cuidar tus sueños así quisiera
Obsequiarte cada segundo*

Resultado:

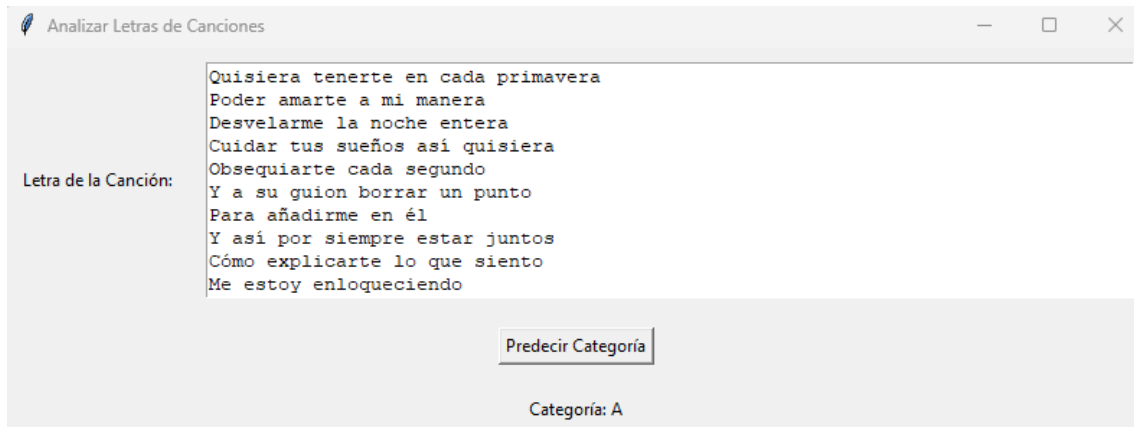


Figura 12 Resultado del sistema

Como se observa en la Figura 13, el sistema nos arroja una clasificación de categoría A, que significa que el contenido de esa letra es apta para todo el público por lo cual es apto para que los niños y el público en general lo puedan escuchar. El código completo se encuentra en la siguiente dirección⁴.

⁴ <https://github.com/DanyDr15/SistemaTesis/tree/master/Programa>

3.1.4 Sistema de transformación de video a texto

Para empezar con el funcionamiento se utilizó el lenguaje de programación Python junto con el editor de texto visual studio code, en el cual se utilizó la extensión de Python para realizar la programación⁵. A continuación, en la Figura 14 se muestra una parte del código siendo esta la más importante porque es el que hace la conversión del archivo de video a texto.

```
19
20  for i in range(0, total_duration):
21      with sr.AudioFile(transcribed_audio_file_name) as source:
22          audio = r.record(source, offset=i*60, duration=60)
23          f = open("transcription.txt", "a")
24          f.write(r.recognize_google(audio, language='es-ES'))
25          f.write(" ")
26  f.close()
```

Figura 13 Interfaz de visual Studio Code

Para realizar la prueba se usó el video musical de Maluma con la música Cuatro Babys que se descargó de la plataforma de YouTube. Después de la ejecución del sistema aparece una interfaz en la cual hay un botón para buscar el video a transcribir, una vez seleccionado se presiona en el botón transcribir video para obtener la transcripción, el tiempo en obtener el resultado va a variar dependiendo del tamaño del archivo. En la Figura 15 en el cuadro de texto se observa el resultado final del sistema transformado a texto.

⁵ <https://github.com/DanyDr15/SistemaTesis/blob/master/Programa/TransfVideoATexto.ipynb>



Figura 14 Resultado del sistema de transformación

3.2 Evaluación de los modelos

Para evaluar los modelos se usaron cuatro métricas de evaluación de clasificación del modelo de aprendizaje automático, siendo estas accuracy, precisión, recall, y f1. Se describe brevemente el significado de cada uno:

- **Accuracy:** Mide el porcentaje de casos que el modelo ha acertado.
- **Precisión:** Con esta métrica se mide la precisión de la calidad del modelo de aprendizaje automático.
- **Recall:** La medida de exhaustividad indica la cantidad que el modelo de aprendizaje automático puede reconocer.
- **F1:** Esta medida fusiona las evaluaciones de precisión y recall en un único valor.

En la Tabla 2 se muestra los resultados que se obtuvieron al evaluar los modelos con una configuración del 75% de sus datos para entrenar y el 25% para el test, así mismo se puede constatar que los modelos con menos porcentajes son el árbol de decisión y el modelo k vecinos más cercanos (KNN), siendo la regresión logística con la puntuación más alta, es decir que es el modelo más adecuado para trabajar con el dataset propuesto.

Tabla 2 Métricas de precisión de los modelos

Métricas	Acurracy	Precisión	Recall	F1
Naive Bayes (NB)	0.59	0.62	0.71	0.68
Regresión logística (RL)	0.75	0.77	0.80	0.74
SVM	0.71	0.74	0.79	0.74
Árbol de decisión (DT)	0.70	0.68	0.76	0.73
KNN	0.55	0.66	0.70	0.65

Para evaluar de mejor manera el sistema, se realizó pruebas con 10 canciones con contenidos sexistas y no sexistas con cada uno de los modelos, como se observa en la Figura 19. En la canción 3 se puede constatar que los modelos, NB, RL y SVM clasifica la canción en 2 que equivale a la categoría B, mientras que DT la clasifica como 1 y KNN lo clasifica como 3, con estas pruebas se confirma que estos dos últimos modelos al momento de realizar la clasificación son los que más margen de error tienen. Así mismo, los resultados indican que solo cuando la letra de la canción es de clase 1 todos los modelos lo clasifican de manera correcta.

Tabla 3 Resultado de pruebas

	NOMBRE	TIP O	NB	RL	SVM	DT	KNN
Canción 1	4 Babys	3	3	3	3	3	3
Canción 2	Yo te robaré – Ozuna	2	2	2	2	2	2
Canción 3	Eres mía – Romeo Santos	2	2	2	2	1	3
Canción 4	Primera cita - cnco	1	1	1	1	1	1
Canción 5	Desesperados - Raw	3	3	3	3	1	3
Canción 6	Culpables - Anuel	3	3	3	3	1	2
Canción 7	Hawai - Maluma	2	2	3	3	1	2
Canción 8	Para enamorarte - CNCO	1	1	1	1	1	1
Canción 9	Una vaina loca – ozuna	2	2	1	3	1	2
Canción 10	Bailando – Enrique Iglesias	2	2	1	2	1	2

Capítulo 4: Discusión

En la investigación de Rasel, Sultana, Akhter y Meesad [54] se menciona que los clasificadores de aprendizaje automático obtuvieron un resultado bastante bueno en el análisis de sentimiento, siendo el algoritmo bosque aleatorio con mayor precisión con un total del 93%, es aquí donde surge una gran diferencia en comparación a los resultados que se obtuvieron en el presente estudio, que fue un total de precisión del 77% con el modelo de regresión logística, esto es por las diferencias del dataset usado, puesto que el presente estudio tuvo que recopilar datos desde cero y crear su propio dataset, mientras que el dataset que se usó en el estudio anteriormente mencionado lo sacaron del sitio web *Data World*, lo que indica que tuvieron un mayor volumen de datos y por ende un mejor resultado en cuanto a precisión.

En [55] se realiza una comparación del algoritmo Naïve Bayes y el proceso del lenguaje natural, en la cual el algoritmo de aprendizaje automático tuvo un porcentaje de 63.5% de precisión siendo este 5.4 veces mejor que el proceso del lenguaje natural, en este caso el mismo modelo usado en este estudio obtuvo un porcentaje de precisión del 62%, sin embargo las pruebas realizadas en el presente estudio arrojaron resultados positivos, puesto que al momento de realizar las pruebas, este modelo clasificaba las letras muy correctamente junto con los otros algoritmos que tenían mayor precisión.

El análisis de sentimientos es posible realizarlo en diferentes ámbitos y para diferentes propósitos, como en el campo de la televisión como se menciona en [12], que busca interpretar el sentimiento del público respecto a los programas que se emiten, en este ámbito también se utilizó el algoritmo Naïve Bayes obteniendo como resultado un 91.67 % de precisión, lo que indica que el modelo que se usa, su precisión va a variar dependiendo de los datos que se utilizan, por otro lado, se confirma que uno de los algoritmos que más se utiliza para realizar análisis de sentimientos es Naïve Bayes por su simpleza, sin embargo, aunque en el presente estudio, no dio un porcentaje tan alto es uno de los algoritmos que menos error tuvo al momento de clasificar las letras de canciones, lo que significa que a pesar de no tener un buen porcentaje de precisión cumple de manera satisfactoria su objetivo.

Capítulo 5: Conclusiones y recomendaciones

5.1 Conclusiones

Las herramientas que incorpora el lenguaje de programación Python, para resolver un problema, en este caso realizar la transformación de un contenido de video a texto, es intuitivo y fácil de usar, sin embargo para el uso que se le quiere orientar que es el de usar el texto para clasificarlo en una categoría no es muy factible puesto que al realizar las pruebas con videos musicales con contenidos sexistas, se pudo constatar que las palabras sexistas no los traduce de manera correcta, siendo estas pieza importante para identificar si la letra de la canción es sexista o no.

La utilización de la tecnología de análisis de sentimientos mediante el aprendizaje automático demostró ser altamente efectiva en categorizar las letras de canciones en sus tres categorías. El logro más significativo fue alcanzar una precisión del 77% utilizando el modelo de regresión logística. Este logro puede ser de gran utilidad para diversas personas, especialmente para padres de familia interesados en evaluar si el contenido lírico de una canción es apropiado para sus hijos.

El rendimiento de los algoritmos al ser evaluados de acuerdo a los parámetros de precisión, se concluye que en su mayoría tienen un alto grado de precisión, siendo descartado los algoritmos de árbol de decisión y vecinos más cercanos, después de realizar una prueba con diez letras de canciones, lo que demostró que estos algoritmos mencionados no eran tan precisos como los demás al momento de categorizar las letras de canciones, pero eso no quiere decir que esos algoritmos son los peores, simplemente indica que para el dataset usado, esos modelos no son muy compatibles. Por otro lado, se constató que al proporcionar más datos al dataset se puede mejorar la precisión de los algoritmos.

5.2 Recomendaciones

Para futuros trabajos similares se recomienda primero buscar y preparar el dataset que se va a usar para entrenar el modelo, puesto que no hay muchos trabajos relacionados explícitamente al tema de estudio, lo que implica que se debe crear el dataset desde cero,

por otro lado, tener muchos datos no siempre implica que el modelo va a tener más precisión, todo depende de la calidad de los datos, es decir, si las etiquetas de salida no tienen coherencia, implicaría que el modelo tienda a tener un margen de error más grande del que debería tener.

Así mismo, se recomienda tener actualizados todas las dependencias de Python como el Microsoft Visual C++, es muy recomendable tenerlo en su última versión, puesto que las librerías que se usan en Python también se van actualizando periódicamente, esto para prevenir posibles errores de compatibilidad, como se dio en el presente estudio al momento de instalar la librería PyAudio, que sirvió en el proceso de transformación de video a texto.

REFERENCIAS

- [1] M. Owda, K. Crockett, and A. Alghamdi, "Harnessing the Power of Text Mining for the Detection of Abusive Content in Social Media," pp. 449–464, 2016.
- [2] H. M. S. T. Sandaruwan, S. A. S. Lorensuhewa, and M. A. L. Kalyani, "Sinhala Hate Speech Detection in Social Media using Text Mining and Machine learning," *19th Int. Conf. Adv. ICT Emerg. Reg. ICTer 2019 - Proc.*, vol. 250, pp. 1–8, 2019.
- [3] T. Vaseeharan and A. Aponso, "Review on Sentiment Analysis of Twitter Posts about News Headlines Using Machine Learning Approaches and Naïve Bayes Classifier," *ACM Int. Conf. Proceeding Ser.*, pp. 33–37, 2020.
- [4] E. Kušen and M. Strembeck, "Politics, sentiments, and misinformation: An analysis of the Twitter discussion on the 2016 Austrian Presidential Elections," *Online Soc. Networks Media*, vol. 5, pp. 37–50, 2018.
- [5] J. Guerreiro and P. Rita, "How to predict explicit recommendations in online reviews using text mining and sentiment analysis," *J. Hosp. Tour. Manag.*, vol. 43, no. November 2018, pp. 269–272, 2020.
- [6] H. Parveen and S. Pandey, "Sentiment analysis on Twitter Data-set using Naive Bayes algorithm," *Proc. 2016 2nd Int. Conf. Appl. Theor. Comput. Commun. Technol. iCATccT 2016*, pp. 416–419, 2017.
- [7] W. Kaswidjanti, H. Himawan, and P. D. P. Silitonga, "The accuracy comparison of social media sentiment analysis using lexicon based and support vector machine on souvenir recommendations," *Test Eng. Manag.*, vol. 82, no. 3–4, pp. 3953–3961, 2020.
- [8] B. T. Pham, K. Khosravi, and I. Prakash, "Application and Comparison of Decision Tree-Based Machine Learning Methods in Landside Susceptibility Assessment at Pauri Garhwal Area, Uttarakhand, India," *Environ. Process.*, vol. 4, no. 3, pp. 711–730, 2017.
- [9] S. Paudel, P. W. C. Prasad, and A. Alsadoon, "Feature Selection Approach for Twitter Sentiment Analysis and Text Classification Based on Chi-Square and

- Naïve Bayes,” *Int. Conf. Appl. Tech. Cyber Secur. Intell. ATCI 2018*, vol. 842, no. 1, pp. 281–298, 2018.
- [10] R. Agrawal and M. Batra, “A Detailed Study on Text Mining Techniques,” *Int. J. Soft Comput. Eng.*, no. 26, pp. 2231–2307, 2013.
- [11] S. P. Kristanto, J. A. Prasetyo, and E. Pramana, “Naive Bayes Classifier on Twitter Sentiment Analysis BPJS of HEALTH,” *Proc. - 2019 2nd Int. Conf. Comput. Informatics Eng. Artif. Intell. Roles Ind. Revolut. 4.0, IC2IE 2019*, pp. 24–28, 2019.
- [12] E. D. Sri Mulyani, D. Rohpandi, and F. A. Rahman, “Analysis of Twitter Sentiment Using the Classification of Naive Bayes Method about Television in Indonesia,” *2019 1st Int. Conf. Cybern. Intell. Syst. ICORIS 2019*, vol. 1, no. August, pp. 89–93, 2019.
- [13] P. Wang *et al.*, “Classification of Proactive Personality: Text Mining Based on Weibo Text and Short-Answer Questions Text,” *IEEE Access*, vol. 8, pp. 97370–97382, 2020.
- [14] Z. Jianqiang and G. Xiaolin, “Comparison research on text pre-processing methods on twitter sentiment analysis,” *IEEE Access*, vol. 5, pp. 2870–2879, 2017.
- [15] M. Youness, E. Mohammed, and B. Jamaa, “A parallel semantic sentiment analysis,” *Proc. 2017 Int. Conf. Cloud Comput. Technol. Appl. CloudTech 2017*, vol. 2018-Janua, pp. 1–6, 2018.
- [16] N. Hadiya and N. Nanavati, “Indic sentiReview: Natural language processing based sentiment analysis on major indian languages,” *Proc. 3rd Int. Conf. Comput. Methodol. Commun. ICCMC 2019*, no. Iccmc, pp. 322–327, 2019.
- [17] M. Khader, A. Awajan, and G. Al-Naymat, “The Effects of Natural Language Processing on Big Data Analysis: Sentiment Analysis Case Study,” *ACIT 2018 - 19th Int. Arab Conf. Inf. Technol.*, pp. 1–7, 2019.
- [18] A. Joshi, B. A. R., and P. Bhattacharyya, “A Fall-back Strategy for Sentiment Analysis in Hindi: a Case Study,” *Proc. 8th ICON*, 2010.
- [19] H. Li, Z. Li, and Z. Rao, “Text mining strategy of power customer service work

- order based on natural language processing technology,” *Proc. - 2019 Int. Conf. Intell. Comput. Autom. Syst. ICICAS 2019*, pp. 335–338, 2019.
- [20] P. O. A. Sunarya, R. Refianti, A. B. Mutiara, and W. Octaviani, “Comparison of accuracy between convolutional neural networks and Naïve Bayes Classifiers in sentiment analysis on Twitter,” *Int. J. Adv. Comput. Sci. Appl.*, vol. 10, no. 5, pp. 77–86, 2019.
- [21] A. P. Jain and P. Dandannavar, “Application of Machine Learning Techniques to Mineral Recognition,” *Computer (Long. Beach. Calif.)*, no. October, pp. 628–632, 2016.
- [22] S. A. S. Neshan and R. Akbari, “A Combination of Machine Learning and Lexicon Based Techniques for Sentiment Analysis,” *2020 6th Int. Conf. Web Res. ICWR 2020*, pp. 8–14, 2020.
- [23] D. Cedeno-Moreno and M. Vargas, “Aprendizaje automático aplicado al análisis de sentimientos,” *I+D Tecnológico*, vol. 16, no. 2, 2020.
- [24] V. Bijalwan, V. Kumar, P. Kumari, and J. Pascual, “KNN based machine learning approach for text and document mining,” *Int. J. Database Theory Appl.*, vol. 7, no. 1, pp. 61–70, 2014.
- [25] S. Developers, “Naive Bayes,” 2020. [Online]. Available: https://scikit-learn.org/stable/modules/naive_bayes.html.
- [26] M. A. Jabbar and S. Samreen, “Heart disease prediction system based on hidden naïve bayes classifier,” *2016 Int. Conf. Circuits, Control. Commun. Comput. I4C 2016*, 2017.
- [27] J. Lilja and M. Ostling, “A comparison of machine learning algorithms for automatic classification of neurons by their morphology,” pp. 1–24, 2018.
- [28] F. A. Sarría and F. Cánovas García, “Modelos predictivos para el estudio del abandono agrícola,” *Abandon. Cultiv. en la Región Murcia consecuencias ecogeomorfológicas*, no. 2016, pp. 161–180, 2015.
- [29] L. K. Ramasamy, S. Kadry, and S. Lim, “Selection of optimal hyper-parameter values of support vector machine for sentiment analysis tasks using nature-inspired optimization methods,” *Bull. Electr. Eng. Informatics*, vol. 10, no. 1,

pp. 290–298, 2021.

- [30] H. Xia, Y. Yang, X. Pan, Z. Zhang, and W. An, “Sentiment analysis for online reviews using conditional random fields and support vector machines,” *Electron. Commer. Res.*, vol. 20, no. 2, pp. 343–360, 2020.
- [31] P. Fortuna and S. Nunes, “A survey on automatic detection of hate speech in text,” *ACM Comput. Surv.*, vol. 51, no. 4, 2018.
- [32] D. Diwakar, R. Kumar, B. Gour, and A. U. Khan, “Proposed Machine Learning Classifier Algorithm for Sentiment Analysis,” *IFIP Int. Conf. Wirel. Opt. Commun. Networks, WOCN*, vol. 2019-December, 2019.
- [33] A. D. Analysis, “Comparative Analysis of Machine Learning KNN, SVM, and Random Forests Algorithm for Facial Expression Classification,” *2016 Int. Semin. Appl. Technol. Inf. Commun.*, pp. 163–168, 2016.
- [34] S. Abuse, “K-Nearest Neighbors Algorithm in Python and Scikit-Learn,” 2018. [Online]. Available: <https://stackabuse.com/k-nearest-neighbors-algorithm-in-python-and-scikit-learn/>.
- [35] D. Apriliani, T. Abidin, E. Sutanta, A. Hamzah, and O. Somantri, “Sentiment analysis for assessment of hotel services review using feature selection approach based-on decision tree,” *Int. J. Adv. Comput. Sci. Appl.*, vol. 11, no. 4, pp. 240–245, 2020.
- [36] Nurfaizah, T. Hariguna, and Y. I. Romadon, “The accuracy comparison of vector support machine and decision tree methods in sentiment analysis,” *J. Phys. Conf. Ser.*, vol. 1367, no. 1, 2019.
- [37] B. Bernd Klein, “What are Decision Trees?,” 2016. [Online]. Available: https://www.python-course.eu/Decision_Trees.php.
- [38] K. Jain and S. Kaushal, “A Comparative Study of Machine Learning and Deep Learning Techniques for Sentiment Analysis,” *2018 7th Int. Conf. Reliab. Infocom Technol. Optim. Trends Futur. Dir. ICRITO 2018*, pp. 483–487, 2018.
- [39] “Diferencias entre Machine Learning y Deep Learning,” 2019. [Online]. Available: <https://openwebinars.net/blog/diferencias-entre-machine-learning-y-deep-learning/>.

- [40] A. Mabrouk, R. P. D. Redondo, and M. Kayed, “Deep Learning-Based Sentiment Classification: A Comparative Survey,” *IEEE Access*, vol. 8, pp. 85616–85638, 2020.
- [41] A. Joulin, E. Grave, P. Bojanowski, and T. Mikolov, “Deep Learning for Hate Speech Detection in Tweets Pinkesh,” *15th Conf. Eur. Chapter Assoc. Comput. Linguist. EACL 2017 - Proc. Conf.*, vol. 2, no. 2, pp. 427–431, 2017.
- [42] S. Paliwal, S. Kumar Khatri, and M. Sharma, “Sentiment Analysis and Prediction Using Neural Networks,” *Proc. Int. Conf. Inven. Res. Comput. Appl. ICIRCA 2018*, no. Icirca, pp. 1035–1042, 2018.
- [43] J. Yu and J. Jiang, “Learning sentence embeddings with auxiliary tasks for cross-domain sentiment classification,” *EMNLP 2016 - Conf. Empir. Methods Nat. Lang. Process. Proc.*, pp. 236–246, 2016.
- [44] L. Di Persio and O. Honchar, “Artificial neural networks architectures for stock price prediction: Comparisons and applications,” *Int. J. Circuits, Syst. Signal Process.*, vol. 10, pp. 403–413, 2016.
- [45] W. Koehrsen, “Recurrent Neural Networks by Example in Python,” 2018. [Online]. Available: <https://towardsdatascience.com/recurrent-neural-networks-by-example-in-python-ffd204f99470>.
- [46] Y. Luo, Y. Cai, Y. Qi, H. Chen, and S. Wang, “Long Short-term Power Load Forecasting Algorithm using Long Short-Term Memory Neural Network with Density-Based Spatial Clustering,” *2019 IEEE 5th Int. Conf. Comput. Commun. ICC 2019*, pp. 125–129, 2019.
- [47] M. Xia, H. Shao, X. Ma, and C. W. De silva, “A Stacked GRU-RNN-based Approach for Predicting Renewable Energy and Electricity Load for Smart Grid Operation,” *IEEE Trans. Ind. Informatics*, pp. 1–1, 2021.
- [48] J. Cheng, S. Zhao, J. Zhang, I. King, X. Zhang, and H. Wang, “Aspect-level sentiment classification with HEAT (HiErarchical ATtention) network,” *Int. Conf. Inf. Knowl. Manag. Proc.*, vol. Part F131841, pp. 97–106, 2017.
- [49] F. Rodriguez-Sanchez, J. Carrillo-de-Albornoz, and L. Plaza, “Automatic classification of sexism in social networks: an empirical study on Twitter data,”

IEEE Access, pp. 219563–219576, 2020.

- [50] A. Dhrodia, “Social media and the silencing effect: Why misogyny online is a human rights issue,” *NewStatesman*, 2017. [Online]. Available: <https://bit.ly/3n3ox68>.
- [51] M. Konstantinovskiy, “What’s the Difference Between Misogyny and Sexism howstuffworks?,” 2020. [Online]. Available: <https://people.howstuffworks.com/misogyny-and-sexism.htm>.
- [52] L. Jiang and Y. Suzuki, “Detecting hate speech from tweets for sentiment analysis,” *2019 6th Int. Conf. Syst. Informatics, ICSAI 2019*, no. Icsai, pp. 671–676, 2019.
- [53] N. B. B, A. Z. B, and O. B. B, *Detecting Hate Speech on Twitter Using a Convolution-GRU Based Deep Neural Network*, vol. 1, no. March. Springer International Publishing, 2018.
- [54] R. I. Rasel, N. Sultana, S. Akhter, and P. Meesad, “Detection of cyber-aggressive comments on social media networks: A machine learning and text mining approach,” *ACM Int. Conf. Proceeding Ser.*, pp. 37–41, 2018.
- [55] B. H. Back and I. K. Ha, “Comparison of sentiment analysis from large twitter datasets by naive bayes and natural language processing methods,” *J. Inf. Commun. Converg. Eng.*, vol. 17, no. 4, pp. 239–245, 2019.
- [56] República de Ecuador, “Constitución del Ecuador,” *Regist. Of.*, vol. 4, pp. 15–217, 2008.
- [57] LOEI, “LEY ORGÁNICA DE EDUCACIÓN INTERCULTURAL,” *Ecuador, Minist. Educ.*, no. 417, pp. 1–85, 2017.
- [58] E. D. E. Motivos, “Ley orgánica de comunicación.”

ANEXO 1. Matrices de confusión de los modelos




Figura 15 Matriz confusión Árbol Decisión




Figura 16 Matriz confusión SVM




Figura 17 Matriz de Confusión Naive Bayes




Figura 18 Matriz de Confusión Regresión Logística




Figura 19 Matriz de Confusión K Vecinos más cercanos