



Universidad
Nacional
de Loja



Carrera de Ingeniería en
Sistemas/Computación.

Facultad de Energía, las Industrias y los Recursos Naturales no Renovables

CARRERA DE INGENIERÍA EN SISTEMAS

Análisis de Sentimientos en Twitter para Descubrir Contenido Xenófobo hacia los Inmigrantes Venezolanos en Ecuador

Línea de investigación: Sistemas Inteligentes

TESIS DE GRADO PREVIA A LA
OBTENCIÓN DEL TÍTULO DE
INGENIERO EN SISTEMAS

Autor:

- Raúl Ramiro Romero Vega.

Director:

- Ing. Oscar Miguel Cumbicus Pineda, Mg.Sc.

LOJA - ECUADOR

2020 - 2021

CERTIFICACIÓN

Ing. Oscar Miguel Cumbicus Pineda

DIRECTOR DE TESIS

CERTIFICA:

Que el egresado **Raúl Ramiro Romero Vega** autor del presente trabajo de titulación, cuyo tema versa sobre **“ANÁLISIS DE SENTIMIENTOS EN TWITTER PARA DESCUBRIR CONTENIDO XENÓFOBO HACIA LOS INMIGRANTES VENEZOLANOS EN ECUADOR”**, ha sido dirigido, orientado, discutido bajo mi asesoramiento y ha sido culminado al 100%, reúne a satisfacción los requisitos exigidos en una investigación de este nivel por lo cual autorizo su presentación y sustentación.

Loja, 28 de agosto del 2020



Firmado electrónicamente por:

**OSCAR MIGUEL
CUMBICUS
PINEDA**

Ing. Oscar Miguel Cumbicus Pineda, Mg. Sc.

DIRECTOR DE TESIS

AUTORÍA

Yo **Raúl Ramiro Romero Vega**, declaro ser autor del presente trabajo de titulación y eximo expresamente a la Universidad Nacional de Loja y a sus representantes jurídicos de posibles reclamos o acciones legales por el contenido del mismo.

Adicionalmente acepto y autorizo a la Universidad Nacional de Loja, la publicación de mi trabajo de titulación en el Repositorio Institucional - Biblioteca Virtual.

Firma:



Firmado electrónicamente por:

**RAUL RAMIRO
ROMERO VEGA**

Cédula: 1105234098

Fecha: 25/01/2021

AGRADECIMIENTO

Mi gratitud infinita para Dios quien me ha brindado salud, sabiduría y todo para llegar a culminar con éxito todas mis metas que las he ido construyendo con esfuerzo y dedicación.

A toda mi familia, en especial a mis padres que han sido el pilar fundamental de apoyo durante mi formación académica.

A mi director del presente trabajo de titulación Ing. Oscar Cumbicus Pineda Mg. Sc. quien con su experiencia y conocimiento me ha sabido orientar de la mejor manera para culminarlo con éxito.

A todos los docentes que formaron parte de mi carrera universitaria, por todo el apoyo y conocimientos brindados de manera desinteresada.

DEDICATORIA

A mis padres Melqui Romero y Sabina Vega por darme su apoyo incondicional, por estar siempre ahí en los buenos y malos momentos.

A toda mi familia que de una u otra manera siempre me han apoyado para que pueda salir adelante.

CARTA DE AUTORIZACIÓN DE TESIS POR PARTE DEL AUTOR, PARA LA CONSULTA, REPRODUCCIÓN PARCIAL O TOTAL Y PUBLICACIÓN ELECTRÓNICA DEL TEXTO COMPLETO

Yo **RAUL RAMIRO ROMERO VEGA**, declaro ser el autor de la tesis titulada: **“ANÁLISIS DE SENTIMIENTOS EN TWITTER PARA DESCUBRIR CONTENIDO XENÓFOBIA HACIA LOS INMIGRANTES VENEZOLANOS EN ECUADOR”**, como requisito para optar al grado de: **INGENIERIA EN SISTEMAS**; autorizo al Sistema Bibliotecario de la Universidad Nacional de Loja para que, con fines académicos, muestre al mundo la producción intelectual de la Universidad, a través de la visibilidad de su contenido en el Repositorio Digital Institucional (RDI):

Los usuarios pueden consultar el contenido de este trabajo en el RDI, en las redes de información del país y del exterior, con las cuales tenga convenio la Universidad.

La Universidad Nacional de Loja, no se responsabiliza por el plagio o copia de la tesis que realice un tercero.

Para constancia de esta autorización, en la ciudad de Loja, a los 25 días del mes de enero del dos mil veintiuno.



Firmado electrónicamente por:

**RAUL RAMIRO
ROMERO VEGA**

Firma:

Autor: Raúl Ramiro Romero Vega

Cédula: 1105234098

Dirección: Loja – Macará, Centenario (Amazonas y Calle 7)

Correo Electrónico: rromerovga@gmail.com

Celular: 0986889241

Teléfono: 072696398

DATOS COMPLEMENTARIOS

Director de Tesis: Ing. Oscar Miguel Cumbicus Pineda, Mg. Sc.

Tribunal de Grado: Ing. Luis Antonio Chamba Eras, Mg.Sc. PhD.

Ing. Cristian Ramiro Narváez Guillen, Mg.Sc.

Ing. Ruperto Alexander López Lapo, Mg.Sc.

TABLA DE CONTENIDOS

ÍNDICE GENERAL

CERTIFICACIÓN	II
AUTORÍA	III
AGRADECIMIENTO	IV
DEDICATORIA	V
CARTA DE AUTORIZACIÓN	VI
TABLA DE CONTENIDOS	VII
ÍNDICE GENERAL	VII
ÍNDICE DE FIGURAS	XI
ÍNDICE DE TABLAS	XIII
1. TÍTULO	1
2. RESUMEN	2
SUMMARY	3
3. INTRODUCCIÓN	4
4. REVISIÓN DE LITERATURA	7
1. Conceptos preliminares	7
Procesamiento de Lenguaje Natural (PLN)	7
Análisis de sentimientos	7
Discursos del odio	7
Xenofobia.....	7
Crowdsourcing.....	7
Machine Translation	8
SMOTE	8
Fine-Tuning.....	8
TFIDF	8
Regresión Logística.....	9
Máquinas de Soporte Vectorial (SVM).....	10

Naive Bayes.....	11
Spyder IDE.....	11
Google Colab.....	11
Twitter Scraper	11
Pandas.....	12
NLTK.....	12
Scikit-Learn.....	12
RegEx	12
JobLib.....	12
MatplotLib	12
GoogleTrans	12
Matriz de confusión.....	13
Accuracy (Exactitud).....	13
Precisión	13
Recall (Exhaustividad).....	14
F1-score (Puntuación F1).....	14
2.Trabajos relacionados	15
5. MATERIALES Y MÉTODOS.....	19
Tipo de investigación	19
Métodos de investigación	19
1. Método científico	19
2. Método sistémico.....	20
Técnicas e instrumentos para la recolección de información.....	20
1. Recopilación documental	20
2. Entrevista.....	21
Tratamiento de la información	21
1. Comprender el dominio de la aplicación y los objetivos del proceso KDT	21
2. Adquisición o selección de un conjunto de datos objetivo	21

3.	Limpieza de datos, preprocesamiento y transformación	22
4.	Desarrollo de modelos y construcción de hipótesis	22
5.	Elección y ejecución de algoritmos de minería de datos adecuados..	22
6.	Interpretación y visualización de resultados	22
6.	RESULTADOS	23
	Objetivo 1: Realizar una revisión bibliográfica acerca del análisis de sentimientos en Twitter.....	23
	Tarea 1: Realizar revisión bibliográfica, basada en las fases de la metodología	23
	Tarea 2: Determinar metodología para el análisis de sentimientos.....	46
	Tarea 3: Identificar el lenguaje de programación, algoritmos, herramientas y software en general necesario para realizar cada una de las fases de la metodología de análisis de sentimientos.	48
	Objetivo 2: Aplicar metodología para el análisis de sentimientos	51
	Tarea 1: Identificar el intervalo de tiempo más conveniente para delimitar la búsqueda y extracción de los tuits	51
	Tarea 2: Ejecutar las fases de la metodología seleccionada en el primer objetivo específico	51
	Objetivo 3: Interpretar los resultados obtenidos en el análisis de sentimientos.	84
	Tarea 1: Analizar e identificar los mejores algoritmos para el análisis de sentimientos.....	84
	Tarea 2: Interpretar los resultados obtenidos.....	86
	Tarea 3: Dar contestación a la pregunta de investigación.....	88
7.	DISCUSIÓN	90
	1.Desarrollo de la propuesta alternativa.....	90
	Objetivo 1: Realizar una revisión bibliográfica acerca del análisis de sentimientos en Twitter.....	90
	Objetivo 2: Aplicar metodología para el análisis de sentimientos.	91
	Objetivo 3: Interpretar los resultados obtenidos en el análisis de sentimientos.....	92
	2.Valoración técnica, económica, ambiental y social.....	93

2.1. Valoración técnica	93
2.2. Valoración económica	93
2.3. Valoración ambiental	95
2.4. Valoración social	95
3. Limitaciones	95
3.1. Fiabilidad de los datos recolectados	95
3.2. Exclusiones y dificultades presentes durante la recolección de los datos 96	
3.3. Falta de estudios relacionados	97
8. CONCLUSIONES	98
9. RECOMENDACIONES.....	99
10. BIBLIOGRAFÍA	101
11. ANEXOS	107
Anexo 1	107
Anexo 2	113
Anexo 3	117
Anexo 4	121
Anexo 5	122
Anexo 6	124
Anexo 7	125
Anexo 8	126
Anexo 9	127
Anexo 10	128
Anexo 11	129
Anexo 12	131
Anexo 13	141

ÍNDICE DE FIGURAS

Fig. 1 Ejemplo de Máquinas de Soporte Vectorial para dos clases [15].....	10
Fig. 2 Matriz de confusión [27]	13
Fig. 3 Proceso de Selección de Estudios	27
Fig. 4 Etapas del Procesamiento del Lenguaje Natural [50]	38
Fig. 5 Marco del análisis de sentimiento basado en la clasificación de tipo de oración usando BiLSTMCRF y 1d-CNN	41
Fig. 6 Representación de las etapas de la metodología KDT	52
Fig. 7 Proceso de la metodología KDT que implementé	52
Fig. 8 Desequilibrio en las clases del dataset 1 de entrenamiento, clasificado por crowdsourcing.....	57
Fig. 9 Equilibrio en las clases del dataset 1 clasificado por crowdsourcing.....	58
Fig. 10 Matriz de confusión del dataset 1 desequilibrado	59
Fig. 11 División del dataset 1 equilibrado	60
Fig. 12 Matriz de confusión del modelo de entrenamiento de Regresión Logística del dataset 1 equilibrado	62
Fig. 13 Matriz de confusión del modelo de entrenamiento de SVM del dataset 1 equilibrado	64
Fig. 14 Matriz de confusión del modelo de entrenamiento de Naive Bayes del dataset 1 equilibrado	66
Fig. 15 Clasificación del dataset 2 (con mensajes hacia inmigrantes venezolanos en Ecuador)	67
Fig. 16 Dataset 2 clasificado y equilibrado por modelo de regresión logística	68
Fig. 17 División de dataset 2 equilibrado, en conjunto de entrenamiento y test.....	69
Fig. 18 División de dataset 2 equilibrado, en conjunto de entrenamiento y validación	69
Fig. 19 Matriz de confusión del modelo de Regresión Logística aplicado al conjunto de validación.....	70
Fig. 20 Matriz de confusión del modelo de Regresión Logística validado con el conjunto principal de Test	71
Fig. 21 Clasificación del dataset 2 por modelo de SVM.....	73
Fig. 22 Dataset 2 clasificado y equilibrado por modelo de SVM.....	74
Fig. 23 División de dataset 2 clasificado (SVM) y equilibrado, en conjunto de entrenamiento y test.....	74
Fig. 24 División de dataset 2 clasificado (SVM) y equilibrado, en conjunto de entrenamiento y validación.....	75
Fig. 25 Matriz de confusión del modelo de SVM aplicado al conjunto de validación ...	76
Fig. 26 Matriz de confusión del modelo de SVM validado con el conjunto principal de Test.....	77
Fig. 27 Clasificación del dataset 2 por modelo de Naive Bayes	78

Fig. 28 Dataset 2 clasificado y equilibrado por modelo de Naive Bayes	79
Fig. 29 División de dataset 2 clasificado (Naive Bayes) y equilibrado, en conjunto de entrenamiento y test.....	79
Fig. 30 División de dataset 2 clasificado (SVM) y equilibrado, en conjunto de entrenamiento y validación.....	80
Fig. 31 Matriz de confusión del modelo de Naive Bayes aplicado al conjunto de validación.....	81
Fig. 32 Matriz de confusión del modelo de Naive Bayes validado con el conjunto principal de test	82
Fig. 33 Precisión global de la matriz de confusión de cada algoritmo	84
Fig. 34 Rendimiento de los modelos para entrenamiento	85
Fig. 35 Clasificación del dataset de acuerdo a cada algoritmo	86
Fig. 36 Media o Promedio porcentual de los tuits clasificados, de acuerdo a cada sentimiento	87
Fig. 37 Resultados del entrenamiento para los nuevos modelos clasificadores del sentimiento xenófobo	88
Fig. 38 Comparativa del rendimiento de los resultados del trabajo relacionado y del presente TT	92
Fig. 39 Tuits recolectados, aún sin procesar	127
Fig. 40 Proceso de Selección de Estudios	134

ÍNDICE DE TABLAS

TABLA I.....	15
TABLA II.....	25
TABLA III.....	26
TABLA IV	47
TABLA V	51
TABLA VI.....	54
TABLA VII.....	55
TABLA VIII.....	56
TABLA IX.....	61
TABLA X.....	62
TABLA XI.....	63
TABLA XII.....	64
TABLA XIII.....	65
TABLA XIV.....	66
TABLA XV.....	70
TABLA XVI.....	71
TABLA XVII.....	72
TABLA XVIII.....	75
TABLA XIX.....	76
TABLA XX.....	77
TABLA XXI.....	80
TABLA XXII.....	81
TABLA XXIII.....	82
TABLA XXIV	86
TABLA XXV	87
TABLA XXVI.....	93
TABLA XXVII	94
TABLA XXVIII	94
TABLA XXIX	94
TABLA XXX	107
TABLA XXXI.....	121

TABLA XXXII	122
TABLA XXXIII	124
TABLA XXXIV	125
TABLA XXXV	126
TABLA XXXVI	128
TABLA XXXVII	129
TABLA XXXVIII	133
TABLA XXXIX	133
TABLA XL	134
TABLA XLI	135
TABLA XLII	135
TABLA XLIII	137
TABLA XLIV	138

1. TÍTULO

Análisis de sentimientos en Twitter para descubrir contenido xenófobo hacia los inmigrantes venezolanos en Ecuador

2. RESUMEN

Ecuador registra un gran número de inmigrantes venezolanos, lo confirma la Organización Internacional de las Migraciones e indica que es el tercer país con el mayor número de inmigrantes venezolanos, y que estos son parte de los países que han presentado los peores indicadores sociales, mostrándose como discriminación étnica y racial, siendo estos indicadores la base de los sentimientos xenófobos entre los países de la región, esto conllevó a la necesidad de determinar su existencia en la población para prevenir que se cometan delitos causados por el odio. El presente Trabajo de Titulación (TT) tuvo el propósito de determinar la existencia de contenido xenófobo en un conjunto de tuits, recolectados entorno a los inmigrantes venezolanos en Ecuador, se lo llevó a cabo mediante las fases de la metodología para el Descubrimiento de Conocimiento en Texto (KDT), las mismas que fueron realizadas en Python, con las librerías más destacadas como NLTK, Imbalanced-Learn y Scikit-Learn, así como la aplicación de Machine Translation para la traducción de los tuits. La xenofobia por ser un sentimiento complejo de identificar a través del procesamiento de lenguaje natural, se tuvo que utilizar otro conjunto de tuits que ya había sido clasificado mediante crowdsourcing, es decir, dichos tuits se clasificaron por humanos de forma colaborativa para detectar discursos de odio y lenguaje ofensivo, dando como salida un modelo ya entrenado que se mejoró mediante fine-tuning (ajuste fino), siendo este la base para el entrenamiento de los algoritmos utilizados en el presente TT, durante el fine-tuning se determinó emplear la Técnica de Sobremuestreo de Minorías Sintéticas (SMOTE) para la creación de datos sintéticos en las clases minoritarias, esta técnica también permitió equilibrar las clases del conjunto de tuits de interés en donde se obtuvo una nueva clasificación dividida en tres sentimientos: xenófobos, ofensivos y otros. Para la obtención de predicciones se ejecutaron tres algoritmos de clasificación supervisados: Máquinas de Soporte Vectorial (SVM), Naive Bayes y Regresión Logística, siendo SVM el algoritmo con mejor desempeño con una puntuación F1 del 94%. Finalmente, se encontró que el 5,76% de los tuits recolectados contienen sentimientos xenófobos, el 31,23% de sentimientos ofensivos y el 63% de los tuits restantes contienen otros sentimientos que van dirigidos hacia los inmigrantes venezolanos en el Ecuador.

Palabras clave: Procesamiento de Lenguaje Natural, Análisis de sentimientos, Python, Xenofobia, Inmigrantes Venezolanos en Ecuador.

SUMMARY

Ecuador registers a great number of Venezuelan immigrants, confirmed by the International Organization of Migration and indicates that it is the third country with the greatest number of Venezuelan immigrants, and that these are part of the countries that have presented the worst social indicators, showing themselves as ethnic and racial discrimination, being these indicators the basis of xenophobic feelings among the countries of the region, this led to the need to determine their existence in the population to prevent hate crimes from being committed. The purpose of present final project (TT) was to determine the existence of xenophobic content in a group of tweets collected from Venezuelan immigrants in Ecuador. This was done through the phases of the Knowledge Discovery in Text (KDT) methodology, which were carried out in Python, with the most important libraries such as NLTK, Imbalanced-Learn and Scikit-Learn, as well as the application of Machine Translation for the translation of the tweets. Xenophobia being a complex feeling to identify through natural language processing, another set of tweets had to be used which had already been classified by crowdsourcing, that is, those tweets were classified by humans in a collaborative way to detect hate speech and offensive language, giving as a result a model already trained which was improved by fine-tuning, being this the base for the training of the algorithms used in the present TT, during the fine-tuning it was determined to use the Synthetic Minority Oversampling Technique (SMOTE) for the creation of synthetic data in the minority classes, this technique also allowed to balance the classes of the set of tweets of interest where a new classification divided in three feelings was obtained: xenophobic, offensive and others. To obtain predictions, three supervised classification algorithms were executed: Support Vector Machine (SVM), Naïve Bayes and Logistic Regression, with SVM being the algorithm with the best performance with an F1 score of 94%. Finally, it was found that 5.76% of the collected tweets contain xenophobic feelings, 31.23% offensive feelings and the remaining 63% contain other feelings that are directed towards Venezuelan immigrants in Ecuador.

Keywords: Natural Language Processing, Sentiment Analysis, Python, Xenophobia, Venezuelan Immigrants in Ecuador.

3. INTRODUCCIÓN

Las redes sociales han sido un medio para hacer públicas nuestras ideas y pensamientos, dando paso a que según Valdez [1] se registre un incremento de los discursos del odio¹, mediante la difusión de mensajes racistas, xenófobos, de intolerancia o que señalen a los demás como una amenaza, que va dirigido mayormente hacia grupos de personas vulnerables, como lo son los extranjeros, siendo causa para ser rechazados en su entorno e incluso con la posibilidad de ser víctimas de delitos causados por este odio.

Ecuador es un país expuesto a la xenofobia en su población, puesto que, de acuerdo a la Organización Internacional para las Migraciones [2], es el tercer país con el mayor número de inmigrantes venezolanos, lo que conlleva a tomar medidas para determinar la existencia de dicho sentimiento en la población. En la actualidad, según Valdez [1], los avances en el campo de la inteligencia artificial, nos permiten determinar la polaridad de los sentimientos presentes en contenidos textuales, lo que da la posibilidad de mejorar estas técnicas con el objetivo de detectar la presencia de otros sentimientos, como en este caso la xenofobia.

En el contexto del presente Trabajo de Titulación (TT), se realizó sobre tres objetivos específicos: Realizar una revisión bibliográfica acerca del análisis de sentimientos en Twitter, Aplicar una metodología para el análisis de sentimientos, y finalmente Interpretar los resultados obtenidos en el análisis de sentimientos; con el propósito de llevar a cabo el objetivo general: Descubrir tuits con contenido xenófobo a inmigrantes venezolanos en Ecuador mediante el análisis de sentimientos en Twitter; ya que su realización conduce a dar contestación a la pregunta de investigación: ¿Existen tuits con contenido xenófobo hacia los inmigrantes venezolanos en Ecuador? Cabe mencionar que este estudio empleó un tipo de investigación cuantitativa, siendo principalmente experimental durante la fase de minería de textos dada por la metodología KDT, complementándose con los métodos de investigación científico y sistémico, que relaciona la ciencia con el conocimiento científico y analiza el problema en su totalidad, complejidad y la forma de interactuar entre las partes.

¹ Discursos del odio: Según Watanabe et al. [6], son discursos que tienen la intención de insultar, ofender o intimidar a una persona debido a algún rasgo (como raza, religión, orientación sexual, nacionalidad o discapacidad)

Para su desarrollo se inició con la ejecución de una revisión bibliográfica basada en las fases de la metodología de Bárbara Kitchenham [3], lo que permitió conocer que existe muy poca información que ayude a la detección de xenofobia en datos textuales, también se determinó la metodología y las herramientas de software para el análisis de sentimientos, así como también técnicas de fine-tuning o ajuste fino que mediante el equilibrio de las clases del conjunto de entrenamiento se ha mejorado el aprendizaje de los modelos de clasificación, optimizando los resultados en las predicciones del algoritmo. Para este TT se aplicaron los algoritmos de clasificación: Regresión Logística, Naive Bayes y Máquinas de Soporte Vectorial, siendo este último el que más tiempo ha tomado en la creación del modelo ya que busca el mejor hiperplano que maximice el margen de separación entre las clases, lo que se refleja como un mejor rendimiento con un 94% de puntuación F1, siguiéndole muy cerca Regresión Logística con un 93% y un 89% para Naive Bayes. Los mismos que permitieron identificar que de los 9888 tuits recolectados, el 5,76% contienen sentimientos xenófobos, el 31,23% de sentimientos ofensivos y el 63% restante contienen otros sentimientos.

Dentro del primer objetivo específico, los resultados de la revisión bibliográfica han sido un aporte importante para trabajos futuros ya que se ha dejado una base concreta del software necesario para el análisis de sentimientos en cuanto a la detección de tuits xenófobos se refiere, así como también, por medio de videos² se detalla la instalación y ejecución de dichos softwares. Durante el segundo objetivo para la aplicación de la metodología KDT se tomó el modelo de clasificación resultante de la investigación de Davidson et al. [4] que detecta discursos del odio, con el propósito de crear un nuevo modelo de clasificación capaz de detectar tuits xenófobos y así dejarlo disponible para trabajos futuros, como la implementación de un software que automatice este proceso de clasificación; finalmente se mejoraron los resultados de rendimiento del modelo inicial, ya que de acuerdo a su autor ofrecía un 90% de puntuación F1, a diferencia del 94% que otorgó el modelo generado por el presente TT. En el tercer objetivo, para la interpretación de los resultados se reconoció que es buena práctica el equilibrio de las clases antes de entrenar un modelo de clasificación, ya que se mejora el desempeño del algoritmo durante las predicciones. Posteriormente, de acuerdo a la clasificación mencionada se determinó que sí existen tuits con contenido xenófobo en el Ecuador hacia los inmigrantes venezolanos.

² https://youtube.com/playlist?list=PLiM6EEUFTvE0r5pbn13MNRML_sgFajscs

Este procedimiento fue realizado a lo largo de las diferentes secciones en el presente TT, como son: la sección de Revisión de literatura, en donde a través de la selección de trabajos relacionados se obtuvo la metodología para el análisis de sentimientos, el lenguaje de programación, algoritmos, herramientas y software en general, lo necesario para realizar cada una de las fases de la metodología de análisis de sentimientos. Más adelante, en la sección de Materiales y Métodos se definió el tipo de investigación, los métodos de investigación aplicados, las técnicas e instrumentos empleadas para la recolección de información y el tratamiento de la información. Posteriormente, se encuentra la sección de Resultados que en base a las tareas de cada objetivo específico del presente TT, se presentaron todos los resultados o hallazgos dados por dichas tareas. En la sección de Discusión, de acuerdo a cada objetivo específico se destacaron qué resultados se han obtenido y qué mejoras o qué aporte ha dado el presente TT frente a los trabajos relacionados; así como también se detallan las limitaciones que se dieron durante su realización. Finalmente, en las secciones de Conclusiones y Recomendaciones se planteó lo que en concreto fue más relevante del presente TT, es decir, las experiencias durante su realización y qué mejoras se pueden dar para ser realizados como trabajos futuros.

4. REVISIÓN DE LITERATURA

A continuación, se presentan las bases teóricas que sustentan el presente Trabajo de Titulación (TT), dicha información ha sido obtenida a través de un proceso de revisión bibliográfica. Esta sección inicia con los conceptos más relevantes entorno a la temática, y posteriormente, se presenta una tabla con todos los estudios que han sido seleccionados durante el proceso de revisión bibliográfica.

1. Conceptos preliminares

Procesamiento de Lenguaje Natural (PLN)

Es un área de estudio enfocado en comprender el lenguaje humano a través del ordenador, consiste en analizar el lenguaje humano, interpretarlo y dar un significado para que sea empleado de manera práctica, tiene aplicaciones como la traducción de idiomas, resumen automático de textos, análisis de sentimientos, reconocimiento del habla, etc., así como también contempla parte de la ciencia de datos, la inteligencia artificial y la lingüística [5].

Análisis de sentimientos

Consiste en tratar de juzgar el sentimiento que hay detrás de un texto, es decir, se analiza para determinar la emoción que la persona está expresando respecto a un producto, noticia o cualquier tema en concreto. Las herramientas de opiniones más básicas son capaces de clasificar textos en positivos, negativos o neutrales [5].

Discursos del odio

Son discursos que tienen la intención de insultar, ofender o intimidar a una persona debido a algún rasgo (como raza, religión, orientación sexual, nacionalidad o discapacidad) [6].

Xenofobia

Consiste en el rechazo generalizado hacia personas de procedencia foránea o extranjera, o en su caso, determinados grupos de origen. Este problema social ha sido la causa de crímenes perpetrados en nombre del nacionalismo y la pureza racial [7].

Crowdsourcing

Es la colaboración o externalización abierta de tareas, en donde trabajadores del sitio CrowdFlower se encargan de clasificar en tres clases (en este caso) a cada uno de los

tuits, cabe recalcar que cada tuit tuvo que haber sido clasificado por al menos tres personas para tomarla como válida a dicha clase [4].

Machine Translation

La traducción automática ha sido una de las aplicaciones más prominentes de inteligencia artificial desde sus inicios, en la actualidad existen redes neuronales para la traducción automática, donde el sistema aprende a traducir entre dos idiomas sin necesidad de cualquier diccionario bilingüe o memorándum de traducción, es decir, el sistema es capaz de extraer los patrones que permiten traducir de un idioma a otro [8].

SMOTE

Es una Técnica De Sobremuestreo De Minorías Sintéticas (ofrecida por la librería Imbalance-Learn) que lleva a cabo un enfoque de sobremuestreo para reequilibrar el conjunto original de entrenamiento. En lugar de aplicar una réplica simple de las instancias de clases minoritarias, la clave de SMOTE es introducir ejemplos sintéticos. Estos nuevos datos se crean por interpolación, entre varias instancias de clases minoritarias que se encuentran dentro de un vecindario definido [9] [10].

Fine-Tuning

El ajuste fino de un modelo se da modificando sus parámetros o aplicando técnicas que mejoren los datos a entrenar, con el objetivo de conducir a un mejor rendimiento del algoritmo [11].

TFIDF

En la representación vectorial, cada palabra en el texto completo, está asociada con una coordenada en un espacio de alta dimensión. El valor numérico de cada coordenada a veces se denomina peso de la palabra. Los *tf x idf* (Término Frecuencia de Documento Inversa) se utilizan como procedimiento de ponderación. Es decir, si $D = \{D_1, D_2, \dots, D_N\}$ es el conjunto de todos los documentos en el corpus, y f_w^i es la frecuencia de la palabra w en el documento D_i . tf_w^i se define como la frecuencia normalizada de w en D_i .

$$tf_w^i = \frac{f_w^i}{\max_{u \in D_i} \{f_w^i\}}$$

De alguna manera, tf describe la importancia de w , localmente en D_i . Por otra parte, idf da una medida global de la importancia de w :

$$idf_w = \log \frac{N}{|\{D_i \mid f_w^i > 0\}|}$$

El producto final, $tf \times idf$ trata de encontrar un equilibrio entre la importancia local y global de un término. Es común usar variantes de tf y idf en lugar de los originales, dependiendo del dominio de aplicación. Se dejar v_i ser el vector de D_i como una matriz ponderada TFIDF de la colección D se crea concatenando todos los vectores individuales, en un orden consistente. Con esta representación, se pueden aplicar varios métodos de aprendizaje automático [12].

Regresión Logística

Según Mejía et al. [13], la regresión logística es un procedimiento cuantitativo de gran utilidad para problemas donde la variable dependiente toma valores en un conjunto finito. Así también puede ser empleada para estimar la probabilidad de aparición de cada una de las posibilidades de un suceso con más de dos categorías. Como por ejemplo, si se da una variable categórica de dos niveles, la regresión logística se encarga de modelar la probabilidad de que Y pertenezca a una categoría o clase, dados los valores de un único predictor X . La clasificación depende del límite que se establezca. $\Pr(Y = k \mid X = x)$. En regresión logística se utiliza la siguiente función logística:

$$p(X) = \frac{e^{\beta_0 + \beta_1 X}}{1 + e^{\beta_0 + \beta_1 X}}$$

Produciendo una curva en forma de S , resultando valores de Y entre $[0, 1]$. La ecuación anterior puede reestructurarse como:

$$\frac{p(X)}{1 - p(X)} = e^{\beta_0 + \beta_1 X}$$

donde $p(X)/[1 - p(X)]$ corresponde a los odds³, pudiendo tomar cualquier valor entre

³ Los odd ratios son usados en modelos de regresión logística para comparar la influencia de las variables independientes sobre la variable dependiente. Al realizar regresiones logísticas, los odd ratios se denominan exponencial de b y se expresan así $\text{Exp}(b)$ [79].

0 (muy baja probabilidad de éxito) y ∞ (muy alta probabilidad de éxito). Este ratio indica cuanto más probable es el éxito que el fracaso.

Máquinas de Soporte Vectorial (SVM)

Las Máquinas de Soporte Vectorial (SVM) son un grupo de métodos de aprendizaje supervisados que puede ser utilizado para la clasificación o regresión. Es una herramienta de aprendizaje de clasificación famosa y efectiva que se utiliza para el reconocimiento de patrones [14].

De acuerdo a Piñón Ferrer [15], el funcionamiento de SVM representa cada valor de entrenamiento como puntos en el espacio, siendo capaz de realizar clasificadores lineales y no lineales utilizando kernels. El funcionamiento básico de un clasificador de SVM se basa en encontrar un hiperplano C que separe los vectores de atributos que representan cada una de las clases, intentando que esta separación sea la máxima posible. Para ello, utiliza dos vectores llamados vectores de soporte S_1 , S_2 que se consideran como atributos y en un espacio bidimensional se representa de la siguiente manera (ver Fig. 1):




Fig. 1 Ejemplo de Máquinas de Soporte Vectorial para dos clases [15]

El hiperplano que separa las clases se representa como una línea, por tratarse de un espacio de dos dimensiones y los vectores de soporte son líneas paralelas al hiperplano separador, así también se puede apreciar las líneas grises que indican la existencia de infinitos hiperplanos que permiten separar los valores en dos clases. Sin embargo, el objetivo es de encontrar aquel hiperplano que permita un margen máximo entre los

elementos de las dos categorías.

Naive Bayes

De acuerdo a Phand et al. [16], este modelo es un clasificador probabilístico fundamentado en el teorema de Bayes, se utiliza para clasificar datos en forma de texto. Al usar este modelo, debemos suponer que el valor en una clase dada y los valores de otra variable son independientes entre sí. Este supuesto se llama independencia condicional de clase. Es un modelo que se enfoca en simplificar el cálculo y en ese sentido se considera “naive” (ingenuo). Por ejemplo, la clase c^* se asigna al tuit que se representa en d donde, $c^* = \operatorname{argmax}_{c \in C} PNB(c|d)$.

$$PNB(c|d) = \frac{P(c) \prod_{i=1}^m P(f_i|c)^{ni(d)}}{P(d)}$$

En la fórmula anterior, la característica se denota por f y es el recuento de características f_i y un tuit d se denota como $ni(d)$. Donde m es el total de características. $P(c)$ and $P(f|c)$ son parámetros definidos a través de estimaciones máximas. El modelo Naive Bayes asume la independencia.

Spyder IDE

Es un poderoso entorno científico escrito en Python y diseñado por y para científicos, ingenieros y analistas de datos. Ofrece una combinación única de la funcionalidad avanzada de edición, análisis, depuración y creación de perfiles de una herramienta de desarrollo integral con la exploración de datos, ejecución interactiva, inspección profunda y hermosas capacidades de visualización de un paquete científico [17].

Google Colab

Es un proyecto de investigación para la creación de prototipos de modelos de aprendizaje automático en opciones de hardware potentes como GPU y TPU. Proporciona un entorno de portátil Jupyter sin servidor para el desarrollo interactivo. Google Colab es de uso gratuito al igual que otros productos de G Suite [18].

Twitter Scraper

Empleando la interfaz Javascript de la API de Twitter y utilizando ingeniería inversa, surgió Twitter Scraper, la misma que no tiene limitaciones de velocidad ni restricciones al extraer tuits [19].

Pandas

Es una herramienta de análisis y manipulación de datos de código abierto, siendo rápida, potente, flexible y fácil de usar, construida sobre el lenguaje de programación Python [20].

NLTK

Natural Language Toolkit es una plataforma líder para crear programas de Python para trabajar con datos de lenguaje humano. Proporciona interfaces fáciles de usar a más de 50 recursos corporales y léxicos como WordNet, junto con un conjunto de bibliotecas de procesamiento de texto para clasificación, tokenización, derivación, etiquetado, análisis y razonamiento semántico, envoltorios para bibliotecas PLN de potencia industrial [21].

Scikit-Learn

Es un módulo de Python que integra una amplia gama de algoritmos de aprendizaje automático de última generación para problemas supervisados y no supervisados de mediana escala. Este paquete se centra en llevar el aprendizaje automático a los no especialistas que utilizan un lenguaje de alto nivel de propósito general [22].

RegEx

Es un módulo de Python que permite el manejo de expresiones regulares que contienen símbolos especiales que se refieren a la palabra que se ha relacionado con una subexpresión específica; lo que nos permite realizar procesos como la limpieza de cadenas [23].

JobLib

Maneja problemas frecuentes, como la paralelización, la memorización y el almacenamiento y carga de objetos, en muy poco tiempo, lo que permite entre otras cosas, la exportación e importación de resultados mediante archivos [24].

MatplotLib

Es una biblioteca completa para crear visualizaciones estáticas, animadas e interactivas en Python [25].

GoogleTrans

Es una biblioteca de Python gratuita e ilimitada que implementó la API de Google

Translate. Esta utiliza la API de Google Translate Ajax para realizar llamadas a métodos como detectar el idioma y traducir [26].

Matriz de confusión

De acuerdo a Deng y Luque et al. [27] [28], la matriz de confusión es un concepto del aprendizaje automático, que contiene información sobre clases reales y predichas, realizadas por un sistema de clasificación. Una matriz de confusión tiene dos dimensiones, una dimensión está indexada por el valor de la clase real de un objeto, el otro está indexado por la clase que predice el clasificador. La Fig. 2 presenta la forma básica de una matriz de confusión para una tarea de clasificación de clases múltiples, con las clases A_1 , A_2 y A_n . En la matriz de confusión, N_{ij} representa el número de muestras que realmente pertenecen a la clase A_i , pero clasificadas como clase A_j .

		Predicted			
		A_1	... A_j ...	A_n	
Actual	A_1	N_{11}	N_{1j}	N_{1n}	
	⋮		⋮		
	A_i	N_{i1}	... N_{ij} ...	N_{in}	
	⋮		⋮		
	A_n	N_{n1}	N_{nj}	N_{nn}	

Fig. 2 Matriz de confusión [27]

Así mismo, según Deng y Luque et al. [27][28] estas son las métricas de rendimiento en base a la matriz de confusión para los algoritmos de clasificación: Exactitud, Precisión, Exhaustividad y Puntuación F1, que se describen a continuación.

Accuracy (Exactitud)

Es la proporción del número total de predicciones que fueron correctas:

$$Accuracy = \frac{\sum_{i=1}^n N_{ii}}{\sum_{i=1}^n \sum_{j=1}^n N_{ij}}$$

Precisión

La precisión es una medida de la exactitud siempre que se haya predicho una clase específica. Está definido por:

$$Precision_i = \frac{N_{ii}}{\sum_{k=1}^n N_{ki}}$$

Recall (Exhaustividad)

Es una medida de la capacidad de un modelo de predicción para seleccionar instancias de una determinada clase de un conjunto de datos, se define por la fórmula:

$$Recall_i = \frac{N_{ii}}{\sum_{k=1}^n N_{ik}}$$

F1-score (Puntuación F1)

Es la media armónica de precisión y recall:

$$F - score_i = \frac{2 * Precision_i * Recall_i}{Precision_i + Recall_i}$$

Puntuación F1 mediante un reporte de clasificación, también presenta los valores de Macro AVG (Promedio Macro) y Weighted AVG (Peso Promedio).

2. Trabajos relacionados

De acuerdo a la revisión bibliográfica realizada, en la TABLA I se presentan los trabajos o estudios relacionados con el presente TT.

TABLA I
ESTUDIOS PRIMARIOS SELECCIONADOS

N°	Estudios seleccionados	Ref.	Términos	Buscador
ES01	Real-time Twitter Sentiment Analysis using 3-way classifier	[29]	R; Sentiment Analysis; Opinion Mining; Polarity; Twitter	IEEE Xplore
ES02	Sentiment Analysis Using RNN And Google Translator	[30]	Tools, Machine Translation	IEEE Xplore
ES03	A case study of Spanish text transformations for twitter sentiment analysis	[12]	Sentiment Analysis, Opinion	ScienceDirect
ES04	Sentiment Analysis Using Supervised Classification Algorithms	[31]	Logistic Regression, Classification, Naive Bayes, Sentiment Analysis	ACM Digital Library
ES05	El análisis de opiniones en la predicción política basados en Twitter. Un nuevo enfoque.	[32]	Twitter, Herramientas, Software, Twitter.	Google Scholar
ES06	Análisis de la Red social Twitter para la identificación de patrones que generan oportunidades de negocio en la ciudad de Guayaquil utilizando el entorno de trabajo Jupyter Notebook y el Lenguaje de Programación Python.	[5]	Análisis de Sentimientos, Twitter, Lenguaje de Programación, Algoritmos.	Google Scholar
ES07	Polaridad de las opiniones sobre un personaje público en el Ecuador	[33]	Análisis De Sentimientos, Procesamiento Del Lenguaje Natural.	ACM Digital Library
ES08	Text Mining for Documents Annotation and Ontology Support	[34]	Methodologies, Natural Language Processing	Google Scholar
ES09	Nuevas Técnicas De Minería De Textos: Aplicaciones	[35]	Metodologías, Procesamiento de Lenguaje Natural, Técnicas.	Google Scholar
ES10	Herramienta para el análisis de opiniones y sentimientos sobre Twitter	[36]	Twitter, Análisis De Sentimientos.	Google Scholar
ES11	MOAS-Les, herramienta para el análisis de sentimientos de textos en idioma español	[37]	Análisis De Sentimientos, Herramientas.	Google Scholar

ES12	Evaluación de Algoritmos de Clasificación para el Minado de Opinión en Twitter	[38]	Algoritmos, Twitter.	ScienceDirect
ES13	Minería de datos aplicada a Twitter y análisis de sentimientos mediante algoritmos de inteligencia artificial	[15]	Twitter, Análisis de Sentimientos, Algoritmos.	Google Scholar
ES14	Herramienta integral de análisis de sentimientos en redes sociales	[39]	Herramientas, Análisis de Sentimientos.	ScienceDirect
ES15	Análisis de sentimientos en sistemas de ticketing IT	[40]	Análisis De Sentimientos, Software.	ACM Digital Library
ES16	Sentiment analysis applied to the popularity level of the ecuadorian political leader Rafael Correa	[41]	Análisis de Sentimientos, Twitter, Procesamiento de Lenguaje Natural.	ScienceDirect
ES17	Sentiment analysis of Twitter data during critical events through Bayesian networks classifiers	[42]	Análisis de Sentimientos, Twitter, Algoritmos.	IEEE Xplore
ES18	New Clustering Algorithms for Twitter Sentiment Analysis	[43]	Algoritmos, Análisis de Sentimientos, Twitter.	IEEE Xplore
ES19	Aplicativo para detectar conductas violentas en Twitter, a través de análisis de sentimientos	[44]	Twitter, Análisis de Sentimientos.	ACM Digital Library
ES20	Application & Comparison of Several Sentiment Analysis Platforms with Open Source Review Dataset	[45]	Software, Análisis de Sentimientos, Algoritmos.	ACM Digital Library
ES21	Supervised learning methods application to sentiment analysis	[46]	Análisis de Sentimientos, Software, Análisis de Sentimientos, Métodos.	ACM Digital Library
ES22	Tuitsenti: Target-dependent tweet sentiment analysis	[47]	Análisis de Sentimientos, Twitter, Algoritmos.	ACM Digital Library
ES23	Lexi-augmenter: Lexicon-based model for tweets sentiment analysis	[48]	Análisis de Sentimientos, Tuits, Métodos.	IEEE Xplore
ES24	Automatic Cyberbullying detection in Spanish-Language Social Networks using Sentiment Analysis Techniques	[49]	Análisis de Sentimientos, Técnicas, Herramientas, Algoritmos.	IEEE Xplore
ES25	Comparación de herramientas de procesamiento de textos en español extraídos de una red social para Python	[50]	Procesamiento de Leguaje Natural, Algoritmos, Lenguaje de Programación.	Google Scholar

ES26	Minería de Opiniones: Análisis de Sentimientos en una Red Social	[51]	Análisis de Sentimientos, Twitter.	ACM Digital Library
ES27	Análisis de Sentimientos a través de Twitter	[52]	Análisis de Sentimientos, Twitter, Algoritmos, Tuits.	ACM Digital Library
ES28	Sentiment Analysis of Twitter Data	[53]	Análisis de Sentimientos, Twitter.	IEEE Xplore
ES29	Comparison of the efficiency of Machine Learning algorithms on Twitter Sentiment Analysis Of Pathao	[54]	Análisis de Sentimientos, Twitter, Algoritmos.	IEEE Xplore
ES30	Enhanced Sentiment Classification Using GEO Location Tweets	[16]	Tuits; Procesamiento de Lenguaje Natural, Análisis de Sentimientos, Twitter.	IEEE Xplore
ES31	Evaluación de técnicas de procesamiento de lenguaje natural para textos cortos en lenguaje español	[55]	Procesamiento de Lenguaje Natural, Técnicas, Análisis de Sentimientos.	Google Scholar
ES32	Sentiment Analysis for Software Engineering: How Far Can We Go?	[56]	Software Engineering, Sentiment Analysis, NLP	IEEE Xplore
ES33	Improving sentiment analysis via sentence type classification using BiLSTM-CRF and CNN	[57]	Natural Language Processing, Sentiment Analysis, Deep Neural Network	ScienceDirect
ES34	Big data quality metrics for sentiment analysis approaches	[58]	Análisis de Sentimientos, Algoritmos.	IEEE Xplore
ES35	Análisis de sentimientos. Aplicación sobre textos en redes sociales	[59]	Análisis de Sentimientos, Twitter.	ACM Digital Library
ES36	Sentiment Analysis on Twitter Data using R	[60]	Análisis de Sentimientos, Twitter, Lenguaje de Programación, Herramientas.	IEEE Xplore
ES37	An Extensive study of Sentiment Analysis tools and Binary Classification of tweets using Rapid Miner	[61]	Text Mining; Sentiment Analysis; Twitter; Rapid Miner	ScienceDirect
ES38	Twitter sentiment classification using stanford NLP	[14]	Opinion, Fetch Twitter Data, Twitter API, Sentiment Analysis	IEEE Xplore
ES39	Estandarización de métricas de rendimiento para clasificadores Machine y Deep Learning	[62]	Clasificador, Métricas de Evaluación, Rendimiento	Google Scholar
ES40	Automated Hate Speech Detection and the Problem of Offensive Language	[4]	Hate Speech, Twitter, Libraries, Algorithm	ACM Digital Library

ES41	Modelo para Analizar Mensajes y Detectar Actitudes Peligrosas a través de Análisis de Sentimientos con Algoritmos de Aprendizajes	[63]	Análisis de Sentimientos, Algoritmos.	ACM Digital Library
ES42	Emotion and Sentiment Analysis from Twitter Text	[64]	Análisis de Sentimientos, Twitter, Tuits.	IEEE Xplore
ES43	Word Sense Disambiguation for Lexicon-Based Sentiment Analysis	[65]	Sentiment Analysis, Lexicon-Based, Opinion Mining	ACM Digital Library

Los hallazgos correspondientes a cada uno de los estudios seleccionados, se presentan en la sección de Resultados debido a que esta revisión de literatura está planteada como un objetivo específico, es por eso que sus hallazgos se plasman en la sección anteriormente mencionada.

5. MATERIALES Y MÉTODOS

Tipo de investigación

Durante la ejecución del presente TT se empleó el tipo de investigación cuantitativa, siendo principalmente experimental, con el propósito de descubrir los sentimientos xenófobos existentes en tuits publicados a inmigrantes venezolanos en Ecuador, a través de algoritmos y técnicas de procesamiento de lenguaje natural.

Así mismo, fue una investigación bibliográfica y de campo, ya que para el cumplimiento de los objetivos se realizó una revisión bibliográfica con el fin de recolectar estudios relacionados, metodología y software necesario para el análisis de sentimientos en Twitter; en lo que respecta a la investigación de campo se la empleó durante la aplicación de entrevistas, realizadas a profesionales en el área de los problemas sociales que conlleva la xenofobia, con el objetivo de justificar y sustentar las razones por las que fue importante la ejecución del presente TT [66].

Métodos de investigación

1. Método científico

Según Castán [67], el método científico es un procedimiento que consiste en la observación sistemática, medición y experimentación, y la formulación, interpretación y modificación de las hipótesis; permitiendo dar respuestas a las interrogantes planteadas por el investigador entorno a la naturaleza de la investigación, concretamente es un método que relaciona la ciencia con el conocimiento científico. Este método se empleó durante el análisis de los estudios seleccionados mediante la revisión bibliográfica, en la cual se hizo una selección de la metodología a utilizar, el lenguaje de programación, los algoritmos y herramientas de software necesarios para el análisis de sentimientos, permitiendo conocer el alcance y eficacia de cada algoritmo que fueron aplicados en los estudios relacionados, para posteriormente estos sean comparados con los resultados obtenidos en el presente TT. A través de la experimentación, se definió las condiciones óptimas necesarias para que un algoritmo de clasificación alcance el mejor desempeño durante la validación y test del modelo (fine-tuning), es decir, se trabajó para la obtención de un conjunto de datos de entrenamiento ideal permitiendo un mejor aprendizaje para cada algoritmo de clasificación.

2. Método sistémico

Según Montes [68], el método sistémico analiza el problema en su complejidad, mediante un proceso que trata la totalidad y la forma de interactuar entre las partes y sus propiedades emergentes resultantes. Este método fue considerado para el presente TT, ya que mediante la aplicación del procesamiento de lenguaje natural se analizó los tuits recolectados previamente, con el propósito de determinar la existencia de sentimientos xenófobos en los mismos.

Técnicas e instrumentos para la recolección de información

1. Recopilación documental

A través de la revisión bibliográfica realizada en base a la metodología de Bárbara Kitchenham [3] se seleccionaron y analizaron 43 trabajos relacionados, los que contribuyeron a dar la sustentación científica al presente TT.

La flexibilidad de la metodología de Bárbara Kitchenham, permitió omitir ciertas subfases que fueron consideradas como no relevantes para dar cumplimiento a los objetivos del presente TT. A continuación, se presenta las fases y subfases que finalmente fueron realizadas.

Planificación de la revisión

- Identificación de la necesidad de una revisión.
- Especificación de las preguntas de investigación.
- El desarrollo de un protocolo de revisión.

Realizar la revisión

- Identificación de la investigación.
- Selección de los estudios primarios.
- Síntesis de los datos.

Revisión de informes

- Dar formato al informe principal.

2. Entrevista

Según Montes [68], la entrevista es una técnica que permite la obtención de información acerca de las características de un problema de un informante clave, dicha información ayuda a cuantificar las características y la naturaleza del objeto de investigación.

Esta técnica se empleó para obtener información que justifique y sustente el presente TT; la misma que fue dirigida a autoridades de la Universidad Nacional de Loja que son profesionales en cuanto a problemas sociales se refiere, estos son: el Dr. Paúl Palacios Especialista de la Unidad de Bienestar Universitario en el Área de Psicología y la Ing. Celia Jara Galdeman Gestora de la Carrera de Trabajo Social, que mediante las entrevistas (ver Anexo 2) contribuyeron con información que resaltaron la importancia de los resultados del presente TT. Las evidencias de dichas entrevistas se las puede encontrar en el siguiente enlace: <https://drive.google.com/open?id=1gNqSMraM3y-aaevO4w7Cbps1MeIjdNKW>.

Tratamiento de la información

Para el tratamiento de la información se empleó la metodología KDT, a través de las siguientes etapas:

1. Comprender el dominio de la aplicación y los objetivos del proceso KDT

En esta primera etapa se reconoció el contexto del problema de investigación, a través del planteamiento de conceptos de los términos más relevantes como las herramientas de software, los algoritmos, el lenguaje de programación e incluso las técnicas que se emplearon para el afinamiento de los modelos de cada algoritmo ejecutado, el planteamiento de estas conceptualizaciones tuvo como propósito comprender todo el dominio de que conllevó realizar este proceso KDT. Así como también, en esta etapa se plantearon los objetivos que se pretendían alcanzar al realizar cada una de las etapas de esta metodología o proceso KDT.

2. Adquisición o selección de un conjunto de datos objetivo

Esta etapa consistió en la recolección de datos de la red social Twitter, estos fueron el objeto de estudio para las etapas restantes del proceso KDT, dichos tuits se recolectaron de acuerdo a ciertas palabras claves y a limitantes como el año y el lugar geográfico de publicación que conllevaron a obtener solo aquellos tuits que están entorno a los inmigrantes venezolanos en Ecuador, el proceso para su recolección fue realizada de manera automática a través de la librería Twitter Scraper.

3. Limpieza de datos, preprocesamiento y transformación

Los tuits recolectados en la etapa anterior, al tratarse de textos no tienen una estructura adecuada para ser analizados correctamente, es por eso, que esta etapa se encargó de asegurar de que no existan caracteres o palabras incompletas que distorsionen la detección de patrones o que no aporten al descubrimiento del conocimiento. Cabe mencionar que las stopwords⁴ se eliminaron durante la vectorización de los tuits para no afectar a la representación del texto.

4. Desarrollo de modelos y construcción de hipótesis

Durante la presente etapa a partir de un conjunto de tuits clasificados por crowdsourcing se procedió a crear, validar y probar la eficiencia de los modelos de cada algoritmo de clasificación, que mediante el fine-tuning de los resultados se obtuvo un modelo óptimo para el entrenamiento de nuevos conjuntos de datos, en este caso se entrenó un modelo entorno a los inmigrantes venezolanos en Ecuador, es decir, es el dataset resultante de la etapa anterior.

5. Elección y ejecución de algoritmos de minería de datos adecuados

En esta etapa se utilizaron los modelos anteriormente entrenados y ajustados, con el fin de que puedan ser correctamente aplicados a los algoritmos que fueron seleccionados durante la revisión bibliográfica. Durante la ejecución de los algoritmos, estos se encargaron de predecir la clase a la que corresponde cada tuit, ya sea que se trate de un sentimiento xenófobo, ofensivo u otro.

6. Interpretación y visualización de resultados

Finalmente, en base a los resultados obtenidos se generaron reportes de clasificación, matrices de confusión y gráficas que facilitaron la interpretación de estos resultados, permitiendo también dar contestación a la pregunta de investigación y de esta manera obtener conclusiones de acuerdo a los objetivos planteados en la primera etapa de este proceso KDT.

⁴ Las stopwords o palabras vacías pueden identificarse como una palabra que tiene la misma probabilidad de aparecer en aquellos documentos que no son relevantes para mi consulta que en aquellos documentos que sí son relevantes para mi consulta [80].

6. RESULTADOS

En la presente sección se detallan los resultados de cada uno de los objetivos específicos del presente TT, lo que lleva al cumplimiento del mismo. Cada objetivo se subdivide en tareas; dentro del primer objetivo se realizó la revisión bibliográfica, a través de las fases propuestas por Bárbara Kitchenham, con el propósito de determinar la metodología para el análisis de sentimientos en Twitter, así como las herramientas de software necesarias que contribuyen a realizar dicho análisis.

A partir del segundo objetivo se ejecutaron las fases de la metodología seleccionada para el análisis de sentimientos, estos resultados se analizaron para su interpretación en el tercer y último objetivo que concluye dando respuesta a la pregunta de investigación del presente TT.

Objetivo 1: Realizar una revisión bibliográfica acerca del análisis de sentimientos en Twitter

Para el análisis de sentimientos en Twitter fue requerido realizar una revisión bibliográfica, en la que se determinó la metodología, lenguaje de programación, algoritmos, herramientas y el software en general necesario y más indicado para el análisis de sentimientos en Twitter. Para su cumplimiento, ha sido desglosado en tres tareas, las mismas que se presentan a continuación, con su respectivo procedimiento.

Tarea 1: Realizar revisión bibliográfica, basada en las fases de la metodología de RSL de Bárbara Kitchenham

La realización de la revisión bibliográfica se basó en el proceso de revisión sistemática de Bárbara Kitchenham [3], dicho proceso se resume en tres fases principales: Planificación de la revisión, Realizar la revisión y Revisión de informes, de las que según su autor algunas tareas de estas fases no son obligatorias, como por ejemplo:

- Puesta en marcha de una revisión, depende de si o no la revisión sistemática que se está haciendo sobre una base comercial.
- Evaluar el protocolo de revisión y la evaluación del informe, son opcionales y dependen de los procedimientos de garantía de calidad decididas por el encargado de la revisión sistemática.

Por lo tanto, para el presente TT no se ejecutaron todas las tareas propuestas por Kitchenham, justamente porque su metodología es flexible en cuanto a la extensión que el investigador necesite dar a su revisión, como por ejemplo, en la fase de Revisión de Informes, se solicita especificar los mecanismos de difusión, los mismos que depende

del alcance que el investigador requiera dar a la presentación y difusión de sus resultados. De acuerdo a esto, se consideró realizar las siguientes fases y subfases o tareas:

Planificación de la revisión

- Identificación de la necesidad de una revisión.
- Especificación de las preguntas de investigación.
- El desarrollo de un protocolo de revisión.

Realizar la revisión

- Identificación de la investigación.
- Selección de los estudios primarios.
- Síntesis de los datos.

Revisión de informes

- Dar formato al informe principal.

A continuación, se detalla el proceso de la revisión bibliográfica realizado de acuerdo a las fases ya planteadas.

1. Planificación de la revisión

Identificación de la necesidad de una revisión

A través de la ejecución de una revisión bibliográfica, se permite descubrir el conocimiento que existe entorno a cierto tema de investigación; en este caso fue necesaria para elegir la metodología, el lenguaje de programación, los algoritmos, las herramientas y el software en general más acorde para el análisis de sentimientos en Twitter. Para cumplir correctamente el alcance anteriormente propuesto se ha determinado ciertas preguntas de investigación.

Preguntas de investigación

Partiendo de la pregunta de investigación inicialmente planteada en el anteproyecto (ver Anexo 13) del presente TT ¿Existen tuits con contenido xenófobo hacia los inmigrantes venezolanos en Ecuador?, se planteó la hipótesis de investigación de que “Sí existen tuits con contenido xenófobo hacia los inmigrantes venezolanos en Ecuador”, la misma que puede ser o no cierta, es decir, con los resultados finales del presente TT se contrastó la validez de dicha hipótesis.

A continuación, en la TABLA II se presentan las preguntas de investigación que definieron el curso de la revisión bibliográfica.

TABLA II
PREGUNTAS DE INVESTIGACIÓN

Preguntas de investigación	
P1	¿Qué metodología de minería de datos/textos es más factible emplear para el análisis de sentimientos en Twitter?
P2	¿Cuál es el lenguaje de programación, algoritmos, herramientas y el software en general necesario para realizar el análisis de sentimientos en Twitter?
P3	¿Cuáles son las herramientas de software necesarias para la interpretación de los resultados obtenidos?
P4	¿Cómo determinar la existencia de sentimientos que están entorno a la xenofobia?

El desarrollo de un protocolo de revisión

Diseño del protocolo de búsqueda

a) Estrategias de búsqueda

Petticrew y Roberts [69], recomiendan criterios para plantear la investigación, mediante el uso de la nemotécnica PICOC (Población, Intervención, Comparación, Resultado y Contexto), se estructuran los cinco componentes para definir la cadena de búsqueda; así como también, para una mejor organización y selección de todos los resultados, se utilizó la herramienta en línea Parsifal⁵, la cual ayuda en el contexto de la Ingeniería del Software para realizar revisiones sistemáticas de literatura.

b) Fuentes bibliográficas

Como fuentes bibliográficas, se seleccionó tres bibliotecas virtuales y un indexador de contenido de literatura científica y académica, estos son:

- IEEE Digital Library (<https://ieeexplore.ieee.org/>)
- Science@Direct (<https://www.sciencedirect.com/>)
- ACM Digital Library (<https://dl.acm.org/>)
- Google Scholar (<https://scholar.google.com/>)

Existen contrariedades entorno a la utilización de Google Scholar como una fuente bibliográfica primaria, a razón de que sus resultados no siempre son estudios científicos, sin embargo, de acuerdo a Zhang [4], Google Scholar es uno de los mejores

⁵ <https://parsif.al/>

indexadores de contenido de literatura científica y académica, pero, advierte que se debe utilizar con cuidado ya que también incluye sitios web que no realizan un control de calidad de sus trabajos científicos, es decir, usado correctamente es válido considerarlo como una fuente bibliográfica primaria y/o secundaria.

c) Definir palabras claves para el problema de estudio

Con la definición de los criterios PICOC se obtuvo un conjunto de palabras claves, las mismas que permitieron construir las cadenas de búsquedas, estas son: Algoritmos, Librerías, Metodologías, Métodos, Procesamiento de Lenguaje Natural, Lenguaje de Programación, Análisis de Sentimientos, Software, Técnicas, Herramientas, Discursos del Odio, Tuits, Twitter. Así como también su traducción al inglés: Algorithms, Libraries, Methodologies, Methods, Natural Language Processing, Programming Language, Sentiment Analysis, Software, Techniques, Tools, Hate Speech, Tweets, Twitter.

d) Cadenas de búsqueda

En la TABLA III se presentan las cadenas de búsqueda que fueron utilizadas tanto en inglés como su traducción al español, se realizaron de acuerdo a cada fuente bibliográfica: IEEE Digital Library, Science@Direct, ACM Digital Library y Google Scholar.

TABLA III
CADENAS DE BÚSQUEDA DE ACUERDO A CADA BIBLIOTECA VIRTUAL

Bibliotecas virtuales	Cadenas de búsqueda
IEEE Digital Library	("hate speech" OR "tweets" OR "twitter") AND ("algorithms" OR "libraries" OR "methodologies" OR "methods" OR "programming language" OR "software" OR "techniques" OR "tools") AND ("natural language processing" OR "sentiment analysis")
Science@Direct	("hate speech" OR "tweets" OR "twitter") AND ("algorithms" OR "libraries" OR "methodologies" OR "methods" OR "programming language" OR "software" OR "techniques" OR "tools") AND ("natural language processing" OR "sentiment analysis")
ACM Digital Library	("hate speech" OR "tweets" OR "twitter") AND ("algorithms" OR "libraries" OR "methodologies" OR "methods" OR "programming language" OR "software" OR "techniques" OR "tools") AND ("natural language processing" OR "sentiment analysis")
Google Scholar	("hate speech" OR "tweets" OR "twitter") + ("algorithms" OR "libraries" OR "methodologies" OR "methods" OR "programming language" OR "software" OR "techniques" OR "tools") + ("natural language processing" OR "sentiment analysis")

e) Criterios de inclusión

Durante la búsqueda, se consideraron los siguientes criterios de inclusión:

- **Fecha de publicación:** artículos publicados desde el año 2016 hasta el 2020
- **Idioma:** se consideraron artículos en inglés y español.
- **Tipos de estudios:** artículos, revistas, libros y tesis.

f) Criterios de exclusión

Se descartaron aquellos documentos que no responden a las preguntas de investigación, así como también los que no cumplen con los criterios de inclusión.

2. Realizar la revisión

Identificación de la investigación

El objetivo de la presente revisión bibliográfica, fue dar respuesta a las preguntas de investigación, a través de la búsqueda del mayor número de estudios primarios que contribuyan con información fiable entorno a los temas de interés.

Selección de los estudios primarios

Para su selección se ha seguido el siguiente proceso (ver Fig. 3).

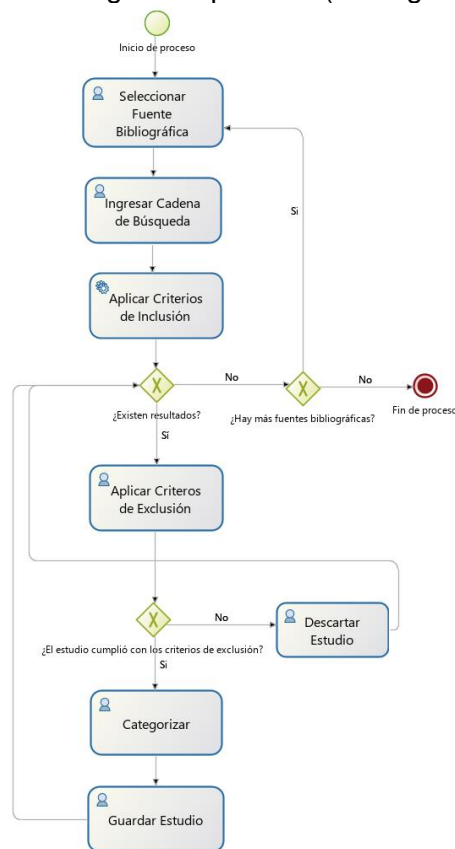


Fig. 3 Proceso de Selección de Estudios

En la sección de Revisión de literatura (ver TABLA I) se presenta la tabla completa con

los trabajos o estudios relacionados que fueron seleccionados.

Síntesis de los datos

Considerando las preguntas de investigación anteriormente planteadas (ver TABLA II): Se obtuvieron un conjunto de 43 trabajos relacionados, los mismos que dieron respuesta a dichas preguntas, en la TABLA I se resumen estos trabajos relacionados. A continuación, se detallan los hallazgos para cada uno de los trabajos relacionados, organizados en 4 categorías que van de acuerdo a las preguntas de investigación planteadas.

Categoría I: ¿Qué metodología de minería de datos/textos es más factible emplear para el análisis de sentimientos en Twitter?

ES01

El estudio [29], presenta un sistema en línea para el análisis y clasificación de sentimientos en Twitter en tiempo real. El sistema propuesto ayuda a los usuarios a ingresar la consulta y obtener una representación gráfica de la polaridad de los tuits. De varios algoritmos de clasificación, los algoritmos Simple Voter Classifier y Naive Bayes Classifier se han utilizado para clasificar los tuits, con una exactitud 74% y 81% respectivamente. Los resultados obtenidos muestran que la precisión del sistema es más eficiente utilizando el clasificador Naive Bayes. La metodología empleada en el trabajo se basa en las siguientes etapas: Extracción de datos, Preprocesamiento, Clasificación del Sentimiento y Representación Gráfica.

ES02

El estudio [30], los puntos focales de este trabajo de investigación son las técnicas que implican PNL (procesamiento del lenguaje natural) en el que se utiliza la Biblioteca de Stanford para aumentar el poder de competencia de la máquina para clasificar más datos que se obtienen de Twitter utilizando la interfaz del programa de aplicación de Twitter, ya que Twitter Now A Days es esa plataforma donde puedes encontrar los tuits sobre una persona en particular o el producto. Por lo tanto, se convierte en una plataforma muy exitosa para obtener datos. Google Translator se utiliza para tener en cuenta esos datos también que no están en inglés. A veces, la obtención de datos implica aquellas oraciones que no están en inglés, por lo que para aumentar la precisión Para la clasificación de sentimientos, ya sea positivo, negativo o neutral, utilizamos el mejor algoritmo de redes neuronales en lugar de algoritmos como la entropía máxima o bayes ingenuos. Al utilizar todas estas técnicas, se ha tratado de encontrar la máxima precisión que otras. La metodología empleada en el trabajo se basa en las siguientes

etapas: Recopilación de los datos de Twitter, Manejo de los datos con Google Traductor, Procesamiento de los datos, Clasificación y Resultados.

ES03

El estudio [12], tiene como objetivo identificar el mayor número de conjunto de combinaciones de transformaciones de texto, como pueden ser:

- Lematización
- Derivación
- Eliminación de entidades, entre otros

y de tokenizadores como n-grams y los esquemas de ponderación de fichas tienen el mayor impacto en la precisión de un clasificador (Máquinas de Soporte Vectorial) entrenado en dos conjuntos de datos. La metodología utilizada es analizar exhaustivamente todas las combinaciones de transformaciones de texto y sus respectivos parámetros para averiguar qué características comunes tienen los clasificadores con mejor desempeño. Además, presenta un enfoque novedoso basado en la combinación de n-grams basados en palabras y q-grams basados en caracteres. Los resultados muestran que esta nueva combinación de palabras y caracteres produce un clasificador que supera a la combinación tradicional basada en palabras en un 11,17% y un 5,62% en los conjuntos de datos.

ES04

La investigación [31], se enfoca al estudio del análisis de sentimiento que resulta de los mensajes de textos u opiniones en Twitter, Facebook, etc., empleando técnicas de búsqueda de textos y clasificación de sentimientos positivos o negativos.

Este estudio compara cinco algoritmos de clasificación supervisados:

- **PART.** - es un aprendizaje de reglas separado para conquistar propuesto por Eibe y Witten. El algoritmo produce conjuntos de reglas llamadas listas de decisiones que son conjuntos ordenados de reglas.
- **Support Vector Machine.** - es un enfoque de clasificación estadística que se basa en la maximización del margen entre las instancias y el hiperplano de separación. El método de la Máquinas de Soporte Vectorial (SVM) se consideró el mejor método de clasificación de texto.
- **Decision Tree.** - clasifica los datos en diferentes clases separando recursivamente el espacio de características en dos partes y asignando diferentes clases en función de la región en el espacio dividido que es una oración, en función de sus características.

- **Naive Bayes.** - ha sido un método muy popular en la categorización de texto debido a su simplicidad y eficiencia.
- **Logistic Regression.** - es un método estadístico para analizar un conjunto de datos en el que hay una o más variables independientes que determinan un resultado. El resultado se mide con una variable dicotómica (en la que solo hay dos resultados posibles).

A partir de los resultados experimentales, luego de realizar la comparación de los algoritmos, se concluye que el algoritmo de regresión logística con un 96,5% parece mejor que los otros cuatro algoritmos para el análisis del conjunto de datos de mensajes de texto (SMS), seguido de SVM con 96% de precisión. La metodología empleada es en base a las siguientes etapas: Conjunto de SMS, Extracción de características, Aplicar algoritmos de clasificación supervisados y Evaluación de los resultados.

ES05

El trabajo [32], emplea una nueva forma o metodología de predicción electoral, se considera nueva ya que la fuente de análisis no toma relevante a los tuits recolectados, sino más bien a los electores, ya que estos influyen como persuasores para otros electores que no tienen un criterio completamente definido hacia cierto partido político; a través de la red social Twitter realizó la recolección de los tuits con sus respectivos autores. La predicción de esta nueva metodología se validó con el resultado real de las encuestas realizadas en Ecuador entre diciembre del 2016 a febrero del 2017. Fueron obtenidos 823135 tuits correspondientes a los electores que seguían las cuentas oficiales de sus partidos políticos y mediante la construcción de un diccionario de palabras tanto positivas como negativas, de 1625 y 2942 respectivamente, utilizando el método de Enfoque Basado en Lexicones para adaptarse al español de Ecuador. La metodología empleada es en base a las siguientes etapas: Formulación del problema, Preparación de los datos, Elección de algoritmos, Optimización de los resultados y Presentación de los resultados.

ES06

El estudio [5], ha sido enfocado en la extracción y análisis de los datos que genera Twitter para contribuir a la toma de decisiones, mediante el uso de análisis de sentimiento en español y algoritmos de aprendizaje automático, generando información útil de apoyo en la toma de decisiones a los emprendedores de la ciudad de Guayaquil con base a la problemática planteada al inicio de sus actividades, o al momento de redireccionar su negocio, la cual consiste en identificar si existe una audiencia para un

determinado producto o servicio y examinar que tipo de sectores e industrias acaparan la mayor cantidad de internautas. Una de las metodologías utilizadas en este proyecto fue la investigación diagnóstica, entre las principales herramientas que posee esta metodología para la recolección de datos y su posterior análisis es la encuesta. Entre los algoritmos a utilizar destacan, algoritmo de clasificación Bayesiano y el uso de una red neuronal para clasificar los tuits por sectores e industrias. El desarrollo de este proyecto fue realizado en Python, en el entorno de desarrollo de Jupyter el cual provee facilidades de uso e implementación de librerías y algoritmos de aprendizaje automático. Este trabajo emplea la metodología CRISP-DM, que consta de seis etapas: Comprensión del negocio, Comprensión de los datos, Preparación de los datos, Modelado, Evaluación y Despliegue.

ES07

El artículo [33], indica la realización de un estudio acerca de las posibles técnicas aplicables a la minería de opiniones, para la obtención de textos en redes sociales de un personaje público en Ecuador, para determinar las polaridad de sentimientos de los usuarios hacia dicho personaje, siendo posible una calificación de su gestión como neutra, positiva o negativa. Dado el análisis de 71845 tuits, dio a conocer que en su mayoría un 92% las opiniones hacia el personaje son neutras, con un 3% de comentarios negativos y un 4% de opiniones positivas que al ser muy bajas no son nada favorables. La metodología empleada en este trabajo es SEMMA creada por SAS Institute, la misma que establece cinco fases: Muestreo, Exploración, Modificación, Modelado y Evaluación.

ES08

El estudio [34], realiza un análisis de los conceptos básicos en el área de la minería de textos y de métodos que se emplean para obtener conocimientos útiles a partir de colecciones de datos textuales. Las técnicas de minería de datos textuales analizadas son: clustering, reglas de asociación y modelos de clasificación. La metodología analizada en este estudio es la Knowledge Discovery in Texts (KDT).

ES09

El estudio [35], tiene como propósito clarificar los conceptos entorno a la Minería de Textos, en el que muchos autores consideran incorrecto aplicar técnicas de minería de datos a los textos ya que dichas técnicas han sido creadas para trabajar con estructuras de datos simples, es decir, tienen una limitada capacidad expresiva; denotan que si se utiliza técnicas de minería de datos en los textos se estaría perdiendo una gran cantidad

semántica, ya que solo se exploraría una pequeña parte de todo el contexto que puede tener un texto. Por lo tanto, para el análisis de datos textuales recomiendan utilizar la metodología de Descubrimiento del Conocimiento en Texto (KDT) que permite aplicar técnicas para el análisis de datos textuales.

Categoría II: ¿Cuál es el lenguaje de programación, algoritmos, herramientas y el software en general necesario para realizar el análisis de sentimientos en Twitter?

ES10

El estudio [36], ha desarrollado un sitio web en el que permite descargar tuits a través de los servicios de Twitter, los que servirán como insumos para cualquier herramienta de análisis de sentimientos, con el propósito de extraer la polaridad de las opiniones expuestas por los usuarios de dicha red social acerca de cualquier tema en general. Este estudio llega a ser útil para cualquier persona que requiera conocer el comportamiento de los usuarios en la internet frente a alguna situación, como por ejemplo: al momento de elegir cierto producto, al determinar la satisfacción de los clientes consumidores de dicho producto e incluso predecir los resultados de futuras elecciones políticas, basándose en las opiniones difundidas en las redes sociales entorno a los candidatos. La clasificación realizada se da en base a las clases: positivo, negativo o neutral, las que representan la polaridad de los sentimientos. Las herramientas para el análisis de sentimientos analizadas en este estudio se presentan en la TABLA XXXV del Anexo 8.

ES11

La investigación [37], determina que existe una escasez de recursos en español para el análisis de sentimientos u opiniones, por esta razón proponen la creación de MOAS-Les, esta es una herramienta que permite expresar la polaridad de textos en idioma español, cumple con esta tarea considerando la orientación semántica, el procesamiento de los intensificadores, atenuadores y oraciones adversativas; esto ayuda enormemente a las investigaciones que en su momento requieran de una herramienta en dicho idioma. Con una muestra de 1000 textos fue evaluado el rendimiento de esta herramienta que utiliza clasificación no supervisada, es decir, se omite la fase de entrenamiento; los resultados de clasificación de polaridad fueron satisfactorios para MOAS-Les con respecto a otros sistemas netamente léxicos o sintácticos.

ES12

La investigación [38], tiene como objetivo analizar los diversos métodos y algoritmos existentes para tratar los textos, en este caso, específicamente de tuits. Expresa un modelo para realizar de forma automática la clasificación de tuits, con el propósito de comprender las intenciones de un usuario al momento de hacer público un tuit. Para esto, determinan ocho categorías, las mismas que utilizan algoritmos de clasificación supervisada, como son: Super Vector Machine (SVM) y Naive Bayes; posterior a la ejecución y evaluación de los algoritmos, determinó que el SVM mantiene un rendimiento y exactitud superior para cumplir con la tarea objetivo, es decir, para la clasificación automática de los tuits.

ES13

La investigación [15], fundamenta de manera teórica y práctica las principales técnicas de minería de datos e inteligencia artificial, aplicados a procesamiento y análisis de los textos encontrados en las redes sociales. Entre estos algoritmos, los que más se destacan son: Análisis de Asociaciones, Agrupamiento, Clasificación y Predicción. Así mismo, realiza dos tareas prácticas, estas son: para el sondeo de redes sociales mediante el análisis de sentimientos de los usuarios en relación a algún tema en particular y también para la búsqueda de clientes potenciales, es decir, muestren interés sobre cierto tema o producto.

ES14

El estudio [39], presenta una herramienta integral de análisis de sentimientos en redes sociales. La cual es una aplicación web que interactúa con Twitter y está dirigida a una amplia gama de usuarios, ya que puede ser utilizada tanto como una actividad recreativa y de disfrute, como así también para analizar la respuesta en las redes sociales a un producto o servicio de determinada empresa o entidad.

ES15

El estudio [40], pretende definir un método para determinar los sentimientos que los problemas declarados en los tickets para soporte Tecnologías de la Información (TI) puedan contener, estos tickets puede crearse a partir de problemas como: de infraestructura, infecciones, errores, incidentes, solicitudes, etc. Determinó un primer desafío al momento de diferenciar automáticamente entre información fáctica (negativa) de aquel sentimiento encontrado en la descripción. Esto lo supera con la creación automática de un diccionario de dominio en que se encuentran todas las palabras

clasificadas de acuerdo a los sentimientos en el contexto de la Tecnología de la Información.

ES16

El trabajo [41], realizó un estudio en el que mediante la herramienta Stanford NLP se analizan qué sentimientos reflejan los mensajes publicados hacia el Ex Presidente del Ecuador Rafael Correa y hacen un contraste con los resultados del candidato oficialista de las elecciones 2017. En concreto, determinaron que los sentimientos hacia el presidente no afectaron a ningún proceso electoral de su partido. La plataforma para la recolección de los mensajes ha sido Twitter, en donde, de los 17818 tuits que corresponden a la precampaña, 8827 han sido clasificados como “negativos”, descalificando la gestión del Ex Presidente Rafael Correa; 4727 tuits fueron “neutrales” y 4264 se determinaron con sentimientos “positivos” evidenciando: amor, gratitud y respaldo hacia el ex presidente. También recogieron una muestra de 5766 tuits durante la campaña electoral, dando los siguientes resultados: 2790 tuits de rechazo, 1641 neutrales y 1335 tuits con mensajes positivos hacia el ex presidente.

ES17

El estudio [42], a través de los clasificadores de red bayesianos realizan análisis de sentimientos en dos conjuntos de datos en español: el terremoto chileno de 2010 y el referéndum de independencia de Cataluña de 2017. Las redes resultantes permiten identificar las relaciones entre palabras, ofreciendo información cualitativa interesante para comprender su histórica y socialmente las características principales de la dinámica del evento. Concluyeron que no hay diferencia en cuanto a cómo se comportan SVM y RF en inglés o español. En cuanto a la precisión de los modelos, mientras que SVM obtuvo el mejor rendimiento en el conjunto de datos 1 y RF en el conjunto de datos 2, el clasificador de red bayesiano también obtuvo resultados competitivos cuando hubo datos suficientes para soportar la estructura de árbol.

ES18

El estudio [43], realiza un análisis de los algoritmos de agrupamiento, estos son una de las soluciones utilizadas para descubrir el sentimiento proporcionado por los usuarios en los tuits. Sin embargo, sabiendo que los sentimientos de los usuarios generalmente se dividen en tres categorías: positivo, negativo y neutral, era obligatorio encontrar un algoritmo de agrupación fuerte, lo que conduce a un buen rendimiento de agrupación y producir un número apropiado de agrupaciones en un nivel aceptable. tiempo de

ejecución. Para lograr este objetivo, combinamos en este documento dos métodos de agrupación bien conocidos: K-means y DENCLUE (Clustering basado en Density) con sus variantes. Esta combinación permite explotar el número preciso de clúster de K-means y el rendimiento de clúster de DENCLUE y sus variantes. Los resultados experimentales en cuatro conjuntos de datos de Twitter demuestran la competitividad de los algoritmos propuestos con respecto a los métodos de vanguardia para proporcionar una compensación entre el rendimiento de la agrupación, el número de agrupaciones devueltas y el tiempo de ejecución.

ES19

El estudio [44], utiliza la red social Twitter como instrumento para realizar un aplicativo capaz de detectar, clasificar, analizar y predecir textos que contengan en ellos signos de violencia a través de la minería de datos y el procesamiento del lenguaje.

Herramientas de software empleadas:

- Python
 - NLTK
 - Pymongo
 - Tweepy
 - Matplotlib
 - NumPy
 - Pandas
 - Sklearn
 - Flask
- Twitter API
- Java
- Spring
- Thymeleaf

La mayoría de los tuits violentos corresponden a usuarios que representan a una institución de protección a los derechos humanos, debido a que, para proteger estos derechos, es necesario hablar de temas de violencia. Así mismo, los tuits violentos no dependen de la ubicación física desde donde fue enviado un estado, sin embargo, existen lugares donde el crecimiento de tuits violentos ha crecido como por ejemplo Ibarra.

ES20

La investigación [45], selecciona tres softwares (Semantria for Excel de Lexalytics, IntenCheck API y KNIME Analytics Platform) para el análisis de sentimientos y los

prueba a través de experimentos en seis conjuntos de datos. Los resultados obtenidos los emplean para definir las características y el alcance que tiene la aplicación de estos softwares. Semantria para Excel, reconoce y califica frases emotivas, a través de métodos de etiquetado, cadenas léxicas y también utiliza un método de aprendizaje no supervisado llamado Syntax Matrix, para reconocer la estructura de la oración y si alguna palabra de negación cambia el sentimiento descubierto en la oración. IntenCheck API, es un potente analizador léxico, que no solo determina sentimientos positivos, negativos o neutrales, sino que también analiza la orientación del sentimiento de otros ángulos como el analizar los comentarios dados por los clientes y aquellas actitudes ocultas que puedan tener. Plataforma de análisis KNIME, permite identificar la orientación del sentimiento con la utilización de sus extensiones de código abierto y métodos basados en análisis léxico. Como resultados, dedujeron que los modelos tienen problemas de sobreajuste, carece de una amplia capacidad de generalización, así mismo como errores en el reconocimiento semántico.

ES21

El estudio [46], compara varios métodos de aprendizaje supervisados, para identificar el mejor modelo para análisis de sentimientos, a través de los valores TF-IDF, métricas y otros parámetros, con el propósito de crear una aplicación real de análisis de sentimientos con información obtenida de Twitter. De acuerdo a los resultados de varios métodos de aprendizaje supervisado, mediante la métrica de Área Bajo la Curva (AUC), el modelo con mejor exactitud ha sido el Árbol de Decisión con un AUC de 0.76. Pero con la tasa de precisión y recuperación (F1) más baja de 0.38 y 0.538. Dichos resultados se encuentran en la TABLA XXXI del Anexo 4.

ES22

El estudio [47], emplea la herramienta Tuitsenti para determinar los sentimientos que pueden verse reflejados en un tweet, obteniendo una o varias entidades de una sola oración. Dichas entidades son empleadas por Tuitsenti para detectar los sentimientos. Este modelo separa el tweet en un contexto derecho e izquierdo de acuerdo con la entidad objetivo, y también explota dos tipos diferentes de incrustaciones de palabras: generales y específicas para representar una palabra. Se utiliza una red neuronal híbrida para capturar la secuencia y la información de la estructura de los dos lados de la entidad objetivo. La información de la secuencia se aprende mediante modelos de redes neuronales recurrentes de Memoria STM a corto y largo plazo (LSTM) bidireccionales basados en la atención. La información de la estructura es capturada por modelos CNN

multicontexto. Teniendo como base este algoritmo, se desarrolló una aplicación web con la que los usuarios pueden interactuar y analizar el sentimiento de una entidad en Twitter en tiempo real.

ES23

La investigación [48], analiza el problema de la automatización del análisis de sentimientos. La investigación en esta área se divide principalmente en dos direcciones:

- Modelos de clasificación que optimizan algoritmos y características para predecir la polaridad de un texto, y
- Modelos basados en léxico que utilizan léxicos y enfoques basados en reglas para determinar el sentimiento de un determinado texto.

Este artículo presenta un sistema que construye un léxico utilizando enfoques basados en diccionarios y contextos y 2,25 millones de tuits recopilados de Twitter. El enfoque basado en el diccionario encuentra palabras clave asociadas semánticamente; sin embargo, este enfoque puede no detectar palabras clave relacionadas contextualmente. Por lo tanto, se aplica la expansión basada en el contexto utilizando redes neuronales e incorporaciones de palabras para encontrar palabras clave relacionadas sintáctica y semánticamente. Los resultados experimentales sugieren que el modelo propuesto produce mejores léxicos y supera al modelo de referencia.

ES24

El estudio [49], emplea técnicas de análisis de sentimientos, como:

- Bolsa De Palabras
- Eliminación De Signos Y Números
- Tokenización
- Derivación
- Clasificador Bayesiano

Los datos utilizados para el entrenamiento del clasificador bayesiano se han obtenido del Diccionario Español de Afectos en el Lenguaje (SDAL), que es una base de datos formada por más de 2500 palabras evaluadas manualmente en tres dimensiones afectivas: agradabilidad, activación (pasivo, activo) y facilidad de imaginar, así mismo, se obtenido 595 palabras siguiendo el mismo procedimiento de SDAL, las cuales se recolectaron con la ayuda de los miembros del Centro de Investigación, Transferencia de Tecnología y Desarrollo de Software (CiTeSoft). Como resultado, el software desarrollado tiene un 93% de éxito en las pruebas de validación realizadas.

ES25

En el estudio [50], se seleccionaron cinco librerías para el lenguaje Python, con el objetivo de comparar algunas funciones básicas del procesamiento de textos, aplicadas a textos cortos en español extraídos de una red social. La tokenización y segmentación de oraciones fueron perfectamente realizadas por dichas herramientas. Se encontraron diferencias en etiquetado gramatical pero los resultados se consideran aceptables. El proceso del Procesamiento de Lenguaje Natural (PLN), generalmente, contempla cuatro tipos de análisis sobre la entrada de un texto en lenguaje natural.



Fig. 4 Etapas del Procesamiento del Lenguaje Natural [50]

Herramientas analizadas en este estudio:

- NLTK
- Freeling
- Pattern.es
- SPACY
- Stanford NLP

En el Anexo 6, se presenta la TABLA XXXIII en la que se compara las herramientas de PLN.

ES26

El estudio [51], complementa algunas áreas de investigación como la categorización de documentos de texto, búsqueda semántica, extracción de entidades con nombre, generación de resúmenes y búsqueda automática de respuestas; mediante un nuevo aspecto a las líneas de investigación, como es el análisis de sentimientos, su objetivo es clasificar textos cortos (opiniones) en seis sentimientos: miedo, ira, asco, sorpresa, tristeza y felicidad. En la primera etapa se recopilaron mensajes de la red social Twitter, muchos de los cuales formarán el corpus de análisis. Posteriormente se están evaluando diversos enfoques para clasificación y detección de sentimientos en los mismos.

ES27

El estudio [52], se encuentra enmarcado dentro de los conceptos de procesamiento del lenguaje natural y analítica del dato cuyo objetivo será desarrollar una aplicación

software con interfaz web que permita realizar un análisis de sentimiento del léxico de una muestra de tuits en la red social Twitter. La investigación se centra en las opiniones que tienen los usuarios identificando los sentimientos positivos y negativos a través de sus tuits. Además, estudia distintas características relacionadas con el lenguaje natural.

ES28

El estudio [53], presenta un modelo que pueda realizar análisis de sentimientos de datos reales recopilados de Twitter. Los datos en Twitter están altamente desestructurados, lo que dificulta su análisis. El presente modelo combina el uso de algoritmos de aprendizaje automático supervisados y no supervisados. El proceso de realizar análisis de sentimientos de la siguiente manera: Tuit extraído directamente de la API de Twitter, luego limpieza y descubrimiento de datos realizados. Después de eso, los datos se introdujeron en varios modelos con fines de capacitación. Cada tuit extraído se clasifica en función de su sentimiento, ya sea positivo, negativo o neutral. Se analizaron datos de McDonalds y KFC para mostrar qué restaurante tiene más popularidad. Se utilizaron diferentes algoritmos de aprendizaje automático. El resultado de estos modelos se probó utilizando varias métricas de prueba, como validación cruzada y puntuación F1. Además, el modelo demuestra un fuerte rendimiento en textos de minería extraídos directamente de Twitter.

ES29

El estudio [54], presenta una forma de analizar automáticamente el sentimiento de los tuits publicados por los usuarios de Pathao (servicio de viaje compartido popular en el sudeste asiático). Se ha fusionado la minería de datos con la minería de texto y la inteligencia computacional para etiquetar los tuits como negativos o positivos. Se ha empleado la API de Twitter para recopilar conjuntos de datos de Twitter y siguiendo el enfoque de aprendizaje supervisado para el desarrollo del corpus de capacitación. Para la clasificación de texto, se ha utilizado tres algoritmos de aprendizaje automático diferentes: Naive Bayes, Support Vector Machine y Logistic Regression. También se ha realizado un análisis comparativo de la eficiencia de estos tres algoritmos de aprendizaje automático, teniendo los siguientes resultados de exactitud: 79,3% para Navie Bayes, el 82.3% para Support Vector Machine y 74,9% para Logistic Regression.

ES30

El estudio [16], recopila más de 30,000 tuits basados en la ubicación de la página de Twitter, también las emociones (emoji) y la forma abreviada de las palabras se usan

para la clasificación de los sentimientos reemplazándolos en forma superior, luego se realiza la clasificación de opinión en 5 categorías, extremas clases positivas, positivas, neutras, negativas y negativas extremas. Los proveedores y los accionistas ayudan a tener en cuenta las opiniones de los modos, transacciones, etc. de una ubicación geográfica particular. También realiza un análisis lógico de muchos productos o servicios en la misma herramienta.

ES31

El estudio [55], analiza y mide el impacto de combinaciones de técnicas y librerías para textos cortos en español, mediante su aplicación en tuits aplicados al análisis de sentimiento, tomando en cuenta parámetros de evaluación en su análisis, el tiempo de procesamiento y características de las técnicas en cada librería. La experimentación demostró que elegir combinaciones de técnicas adecuadas en el preprocesamiento, proporciona una mejora de hasta un 5% y 9% en el rendimiento de la clasificación.

ES32

El estudio [56], indica que las herramientas de análisis de sentimientos brindan resultados poco confiables cuando se usan de manera inmediata, ya que no están diseñadas para procesar conjuntos de datos de tareas de ingeniería de software (SE). Las silver bullet (solución milagrosa) para una aplicación exitosa de las herramientas de análisis de sentimientos a los conjuntos de datos SE podría ser su personalización al contexto de uso específico. Para alcanzar el objetivo, se ha vuelto a entrenar, en un conjunto de 40k oraciones / palabras etiquetadas manualmente extraídas de Stack Overflow, una herramienta de análisis de sentimientos de vanguardia que explota el aprendizaje profundo. A pesar de un proceso de capacitación que requiere tanto esfuerzo y tiempo, los resultados fueron negativos. Se ha realizado una investigación exhaustiva de la precisión de las herramientas de uso común para identificar el sentimiento de los textos relacionados con SE. Mientras tanto, también se ha estudiado el impacto de diferentes conjuntos de datos en el rendimiento de la herramienta. Los resultados deberían advertir a la comunidad investigadora sobre las fuertes limitaciones de las herramientas actuales de análisis de sentimientos.

ES33

El estudio [57], propone un enfoque basado en divide y vencerás:

- Clasifica las oraciones en diferentes tipos
- Realiza un análisis de sentimiento para cada tipo de oración

Encontraron que una oración tiende a ser más compleja si contiene más objetivos de sentimiento, en consecuencia, se recomienda emplear primero una red neuronal que se enfoque en clasificar en tres tipos de sentimientos, así mismo que vaya de acuerdo al número de objetivos que aparecen en cada oración. Cada grupo de las oraciones se introducen en una red neuronal convolucional unidimensional por separado para la clasificación de sentimientos. Su enfoque ha sido evaluado en cuatro conjuntos de datos de clasificación de sentimientos y comparados con una amplia gama de líneas de base. Los resultados experimentales muestran que:

- La clasificación del tipo de oración puede mejorar el desempeño del análisis de sentimientos a nivel de oración.
- El enfoque propuesto logra resultados de vanguardia en varios conjuntos de datos de evaluación comparativa.

A continuación, se presenta el enfoque para mejorar el análisis de sentimientos a través del tipo de clasificación de oración.

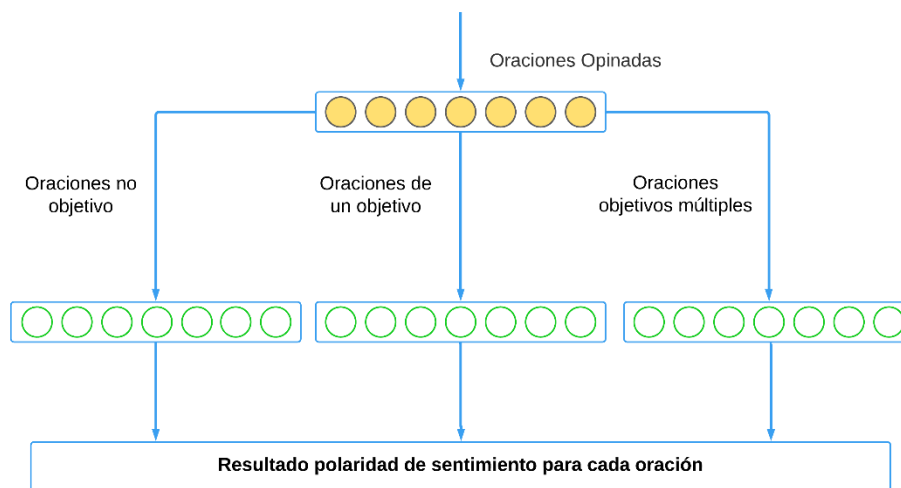


Fig. 5 Marco del análisis de sentimiento basado en la clasificación de tipo de oración usando BiLSTMCRF y 1d-CNN⁶

Una oración de ejemplo con etiquetas en formato *IOB*. El objetivo es el *acto*, la etiqueta *B* indica el comienzo de un objetivo, *I* indica que la palabra está dentro de un objetivo, y *O* indica que una palabra no pertenece a ningún objetivo, dicho ejemplo se desarrolla en la TABLA XXXIV del Anexo 7.

⁶ T. Chen, R. Xu, Y. He, y X. Wang, "Improving sentiment analysis via sentence type classification using BiLSTM-CRF and CNN", *Expert Syst. Appl.*, vol. 72, pp. 221–230, 2017.

Categoría III: ¿Cuáles son las herramientas de software necesarias para la interpretación de los resultados obtenidos?

ES34

En el estudio [58], se destaca las métricas de calidad más importantes que se pueden considerar en los proyectos de Big Data, con el enfoque aplicado al análisis de sentimientos. Destacan que la mala calidad de los datos podría afectar la efectividad del análisis de datos, dando cabida a la generación de errores para la toma de decisiones. Se presenta Las Métricas De Calidad Big Data consideradas se presentan en la TABLA XXXII del Anexo 5.

ES35

En el estudio [59], tienen el propósito de demostrar las capacidades del análisis de sentimientos aplicado a las opiniones emitidas en las redes sociales. Resultados de los algoritmos aplicados: Neural Network 68% de precisión, SVM 71%, Naive Bayes 68% y Random Forest 68%, dejando a SVM como el algoritmo con mejor rendimiento para este trabajo. También se indica que para la evaluación de los resultados para modelos multiclase se lo realiza mediante métricas a partir de un conjunto de puntuaciones de predicción. Estas métricas a utilizar son típicas para una clasificación binaria, éstas son: mecanismo para calcular la exactitud, precisión, Recall, puntuación F1 y la matriz de confusión. Por lo otro lado, las fases de la metodología empleada en este trabajo son: Adquisición de datos, Preprocesamiento de datos, Extracción de características, Utilización de los datos, Modelos clasificadores y Evaluación de modelos.

ES36

El estudio [60], presenta un enfoque de código abierto en el que se ha recopilado tuits por medio de la API de Twitter y luego mediante R se ha preprocesado, analizado y visualizado estos tuits. Este análisis de sentimientos se basa clasificar las perspectivas de las personas en ocho clasificaciones distintas de sentimiento: disgusto, miedo, enojo, anticipación, tristeza, confianza y sorpresa, además de dos sentimientos únicos (positivo y negativo). Los pasos o fases utilizadas en este trabajo son: Crear cuenta de Twitter, Autenticarse en su API, Recopilar tuits, Limpieza de datos, Extracción de textos, Crear nube de palabras, Evaluar resultados. Y la forma de representar los resultados es creando histogramas a partir de los sentimientos clasificados.

ES37

El estudio [61], realiza un análisis de veinte herramientas (ver TABLA XXXVII en Anexo 11) para el análisis de texto con respecto a sus aplicaciones y disponibilidad para el análisis de sentimientos, también se comparan diferentes algoritmos para encontrar el de mayor rendimientos. La herramienta que sobresale es RapidMiner ya que es un software de código abierto, y esto beneficia a los investigadores a realizar libremente experimentos en él; además tiene una interfaz de usuario y flujo de trabajo que lo hace diferente a otras herramientas de código abierto. Dicha herramienta permite generar fácilmente gráficas para evaluar los resultados, como son: los gráficos de elevación, gráfico de los predictores más importantes, matrices de confusión y reporte de clasificación para cada algoritmo.

ES38

El estudio [14], analiza un conjunto de tuits para encontrar el enfoque de los usuarios o clientes donde pueden tener los sentimientos: positivo algo positivo, negativo, algo negativo, neutral o negativo. Estos resultados ayudarán al proveedor de servicios a conocer la opinión de los clientes sobre sus productos. En el que aplicaron los algoritmos de Máquinas de Soporte Vectorial, Naive Bayes y Máxima Entropía que, de acuerdo a este trabajo, tuvieron una exactitud del 100%, 90% y 89%, respectivamente. Se emplean algunas métricas para la evaluación de los resultados, como son: La exactitud, precisión, puntuación F1 y matrices de confusión, en las que se a través de gráficas de barras como salida contienen los resultados de la polaridad de los sentimientos negativo, algo negativo, neutral, algo positivo y positivo respectivamente.

ES39

El estudio [62], tiene como objetivo diseñar una librería en R que permita estandarizar la métricas de rendimiento de los algoritmos, trabaja con las métricas: exactitud, Recall, curva ROC, AUC, matriz de confusión, puntuación F1 e índice Kappa. La librería creada la aplica a tres métodos de clasificación (Análisis Lineal Discriminante, Support Vector Machine y Random Forest), resultando comprueba que la métrica más sensible y eficaz para la evaluación de un clasificador con clases desbalanceadas es la índice kappa.

Categoría IV: ¿Cómo determinar la existencia de sentimientos que están entorno a la xenofobia?

ES40

El estudio [4], utiliza un léxico de discursos del odio para recopilar tuits que contengan palabras clave de discurso de odio, a través de crowdsourcing etiquetaron estos tuits en tres categorías: discursos del odio, lenguaje ofensivo y ninguno. El 11,6% de los tuits se marcaron como discurso de odio, un 76% se consideraron como lenguaje ofensivo y el resto como no ofensivo (categoría ninguna). Dichos resultados de crowdsourcing fueron empleados para entrenar un clasificador. Aplicaron los algoritmos: Regresión logística, Bayes ingenuos, 'Arboles de decisión, Bosques aleatorios y SVM lineal; luego de su aplicación y mediante validación cruzada concluyeron que los algoritmos de regresión logística y SVM lineal tendieron a funcionar significativamente mejor que el resto, con una precisión global del 91% y puntuación F1 del 90%.

ES41

El estudio [63], destaca que al detectar a tiempo los diferentes tipos de actitudes tanto violentas o peligrosas en las redes sociales se puede llegar a prevenir sus efectos que generalmente llegarían a ser negativos. Es por eso que se trata de resolver el tema de seguridad, específicamente las actitudes sospechosas hacia la violencia de género o bullying. De manera concreta pretenden realizar y ofrecer un modelo que conlleve al análisis y extracción de información como mensajes u opiniones públicas que se encuentran en las redes sociales, para demostrar con diversos métodos de aprendizaje, entre estos se destacan: la minería de datos y análisis de sentimientos, permitiendo detectar a tiempo al autor de mensajes u opiniones que llegan a ser violentos o peligrosos.

ES42

El estudio [64], detecta y analiza el sentimiento y la emoción expresados por las personas a partir del texto en sus publicaciones de Twitter y usarlos para generar recomendaciones. Se ha recopilado tuits y respuestas sobre algunos temas específicos y crearon un conjunto de datos con texto, usuario, emoción, información de sentimientos, etc. Utilizando el conjunto de datos para detectar el sentimiento y la emoción de los tuits y sus respuestas y medir los puntajes de influencia de los usuarios en función de varios parámetros basados en el usuario y en los tuits. Finalmente, se ha empleado esta última información para generar recomendaciones generalizadas y personalizadas para los usuarios en función de su actividad en Twitter. El método que

utilizado en este documento incluye algunas novedades interesantes como:

- Incluir respuestas a tuits en el conjunto de datos y mediciones
- Introducir puntajes como: puntaje de sentimiento y puntaje de emoción de las respuestas en el cálculo del puntaje de influencia
- Generar recomendación general y personalizada que contiene una lista de usuarios que acordaron el mismo tema y expresaron emociones y sentimientos similares hacia ese tema en particular.

ES43

El estudio [65], menciona que investigaciones recientes encontraron que las palabras ambiguas se están convirtiendo en el único problema en el análisis de sentimientos basado en léxico. Este estudio trata de manejar un problema ambiguo agregando un proceso de Desambiguación de Sentido de las Palabras. Implementaron varios métodos de relación semántica basada en PATH para encontrar el sentido más apropiado. El resultado muestra que el proceso de desambiguación del sentido de las palabras puede mejorar el rendimiento del análisis de sentimientos. Cuando se combina con la desambiguación del sentido de las palabras, la clasificación f-score es mejor que el análisis de sentimientos sin la desambiguación del sentido de las palabras.

Conclusión general de la Revisión de literatura

Muchos de los autores de cada trabajo relacionado no mencionan una metodología en concreto para realizar el análisis de sentimientos en Twitter, sino que plantean una serie de pasos para llegar a realizar el mismo fin, mediante una comparación de estos pasos genéricos con los de las metodologías encontradas, se concluyó en utilizar la metodología KDT para el análisis de sentimientos xenófobos en Twitter. Así mismo, se determinó que los algoritmos Regresión Logística, Máquinas de Soporte Vectorial y Naive Bayes son los que mejor desempeño tienen para el análisis de datos textuales y clasificación a través de modelos de aprendizaje supervisado. Y las librerías como NLTK, Imbalanced-Learn y Scikit-Learn son las que mayormente destacan en los estudios encontrados, ya que NLTK ofrece un amplio kit de herramientas para el procesamiento de lenguaje natural como diccionarios de stopwords, lematización, tokenización, etc., Imbalanced-Learn cuenta con la Técnica de Sobremuestreo de Minorías Sintéticas (SMOTE) y Scikit-Learn proporciona los algoritmos de clasificación necesarios para el proceso de análisis de sentimientos. Finalmente, para detectar la xenofobia en los tuits, se concluyó que se puede realizar a través del afinamiento de un

modelo inicialmente creado por Davidson T.⁷, el cual clasificó un conjunto de tuits mediante crowdsourcing, los mismos que contenían mensajes con discursos del odio y lenguaje ofensivo.

3. Revisión de informes

Dar formato al informe principal

Como informe final de la revisión bibliográfica realizada, se redactó un artículo como producto final (ver Anexo 12).

Tarea 2: Determinar metodología para el análisis de sentimientos.

De acuerdo a los estudios [5] [12] [29] [30] [31] [32] [33] [34] [35] el análisis de sentimientos en Twitter se puede realizar mediante las siguientes fases:

- Obtención de tuits
- Extracción de características
- Preprocesamiento de los datos
- Aplicación de algoritmos supervisados
 - Training Set
 - Testing Set
- Evaluación
- Representación gráfica

Dichas fases se las pudo contrastar con la metodología para el descubrimiento del conocimiento en texto (utilizada en los estudios [34] [35]), conocida como KDT (Knowledge Discovery in Text) que de acuerdo a Elmenreich [34], consta de las siguientes etapas:

- Comprender el dominio de la aplicación y los objetivos del proceso KDT
- Adquisición o selección de un conjunto de datos objetivo
- Limpieza de datos, preprocesamiento y transformación
- Desarrollo de modelos y construcción de hipótesis
- Elección y ejecución de algoritmos de minería de datos adecuados
- Interpretación y visualización de resultados

Relacionando las etapas de la metodología KDT (Descubrimiento De Conocimiento En Texto) con las fases propuestas por los autores ya mencionados, se consideró factible

⁷ T. Davidson, D. Warmesley, M. Macy, and I. Weber, "Automated Hate Speech Detection and the Problem of Offensive Language," in *Proceedings of the 11th International AAAI Conference on Web and Social Media*, 2017, pp. 512–515.

emplear dicha metodología para el análisis de sentimientos en Twitter. A continuación, en la TABLA IV se presenta dicha relación.

TABLA IV
RELACIÓN DE LAS FASES PARA EL ANÁLISIS DE SENTIMIENTOS EN TWITTER Y KDT

Fases para el análisis de sentimientos en Twitter	Etapas de la metodología KDT
<ul style="list-style-type: none"> • Obtención de tuits 	<ul style="list-style-type: none"> • Comprender el dominio de la aplicación y los objetivos del proceso KDT • Adquisición o selección de un conjunto de datos objetivo
<ul style="list-style-type: none"> • Extracción de características • Preprocesamiento de los datos 	<ul style="list-style-type: none"> • Limpieza de datos, preprocesamiento y transformación
<ul style="list-style-type: none"> • Aplicación de algoritmos supervisados <ul style="list-style-type: none"> ○ Training Set ○ Testing Set 	<ul style="list-style-type: none"> • Desarrollo de modelos y construcción de hipótesis • Elección y ejecución de algoritmos de minería de datos adecuados
<ul style="list-style-type: none"> • Evaluación • Representación gráfica 	<ul style="list-style-type: none"> • Interpretación y visualización de resultados

Cabe mencionar que, en los estudios encontrados durante la revisión bibliográfica, la mayoría de sus autores no especifican una metodología para el análisis de los textos, esto no significa que no lleven un orden en el proceso para dicho análisis, sino que emplean solo las fases que estrictamente requieran para dar cumplimiento a su propósito de análisis de sentimientos.

Finalmente, se consideró factible utilizar la metodología KDT para el análisis de sentimientos en Twitter, siendo imprescindible para dar cumplimiento con el propósito del presente TT.

Tarea 3: Identificar el lenguaje de programación, algoritmos, herramientas y software en general necesario para realizar cada una de las fases de la metodología de análisis de sentimientos.

De acuerdo a los estudios [15] [16] [36] [37] [38] [39] [40] [41] [42] [43] [44] [45] [46] [47] [48] [49] [50] [51] [52] [53] [54] [55] [56] [57] analizados en la revisión bibliográfica, se seleccionó el lenguaje de programación, algoritmos, herramientas y el software general necesario que, según los autores de dichos trabajos, han dado los mejores resultados en cuanto al tratamiento de textos, para la recolección de tuits y el análisis de sentimientos de los mismos. Mediante la construcción de una matriz se ha ido seleccionando los trabajos con su respectivo aporte en cuanto a esta tarea se refiere, dicha matriz está presente en el Anexo 1 (ver TABLA XXX).

A continuación, se describe el lenguaje de programación, los algoritmos y las herramientas de software con la justificación por las que también fueron seleccionadas.

Lenguaje de programación

Python

Como lenguaje de programación fue seleccionado principalmente por el gran número de librerías de uso libre que están disponibles para este lenguaje, además que están orientadas a la realización de proyectos de machine learning, también destacó por la simplicidad en su sintaxis, en comparación con otros lenguajes.

Algoritmos de clasificación

Regresión Logística

Este algoritmo fue seleccionado porque permite realizar predicciones en base a una variable categórica, es decir puede tomar cierto número de clases en donde se consideró tres categorías de sentimientos: xenófobos, ofensivos y otros. Así como también, de acuerdo a los estudios seleccionados (ver Anexo 1) se destaca que ha tenido un muy buen rendimiento en las tareas de clasificación.

Máquinas de Soporte Vectorial (SVM)

Fue elegido la Máquinas de Soporte Vectorial porque en base a los estudios seleccionados (ver Anexo 1), es uno de los algoritmos con mejor desempeño en su clasificación y esto se debe a que separa las clases con la mayor amplitud posible mediante un hiperplano de separación, lo que a posterior le permite al algoritmo clasificar y diferenciar una clase de otra.

Naive Bayes

Así mismo, este algoritmo fue seleccionado por tratarse de un clasificador probabilístico, el cual, para realizar las predicciones toma a cada una de las clases como variables independientes entre sí, lo que hace que realice sus cálculos de forma más simple, Así como también, de acuerdo a los estudios seleccionados (ver Anexo 1) se destaca que ha tenido un muy buen rendimiento en las tareas de clasificación.

Herramientas de software

Spyder IDE

Se consideró utilizar este IDE para ejecutar Python por ser un entorno completo, con una suite de herramientas que facilitaron la programación mediante la presentación de los valores de las variables, presentación de gráficos, la posibilidad de ejecutar varias terminales en una misma sesión, así como también por su intuitiva interface de usuario.

Google Colab

Fue considerado como un entorno para ejecutar código Python, principalmente por las prestaciones que ofrece en cuanto a recursos de hardware se refiere, específicamente, contribuyó en la tarea de Machine Translation.

Bibliotecas o Librerías

Twitter Scraper

Se consideró utilizar esta librería principalmente por las facilidades que ofrece para la extracción de tuits, pues no tiene límites en la antigüedad de los mismos, además de que no requiere disponer de una cuenta en Twitter.

Pandas

Se la consideró por ser una poderosa herramienta que permite manipular los datos de una forma rápida y eficaz.

NLTK

Este conjunto de herramientas para el procesamiento de lenguaje natural fue considerado por su amplio conjunto de librerías que ofrece para la tokenización, derivación, etiquetado, análisis y razonamiento semántico, además que proporcionó una lista de stopwords para el preprocesamiento de los textos.

Scikit-Learn

Este módulo fue elegido porque integra una amplia gama de algoritmos de aprendizaje

automático para problemas supervisados y no supervisados, para el presente TT se utilizaron los siguientes algoritmos: Regresión Logística, Máquinas de Soporte Vectorial y Naive Bayes.

Imbalanced-Learn

De esta librería se empleó la Técnica de Sobremuestreo de Minorías Sintéticas (SMOTE) la cual fue considerada para crear muestras sintéticas de las clases minoritarias con el propósito de mejorar el entrenamiento de los modelos, ya que se obtiene un conjunto de datos con las clases equilibradas.

RegEx

Se consideró emplear esta librería para facilitar la limpieza y preprocesamiento de los datos, pues, mediante el uso de expresiones regulares fue capaz de eliminar los símbolos especiales, espacios, signos de puntuación, etc.

JobLib

Se utilizó esta librería debido a la necesidad de exportar los modelos creados con los algoritmos, así como los nuevos dataset limpios, procesados o traducidos.

Matplotlib

Para la representación gráfica de los resultados del presente TT, se consideró utilizar esta poderosa librería que es capaz de crear visualizaciones estáticas, animadas e interactivas.

GoogleTrans

Esta librería se utilizó para realizar Machine Translation, la misma que emplea el motor de traducción de Google para realizar las traducciones automáticas de idioma, también destacó porque no tiene limitaciones durante su utilización.

A continuación, en la TABLA V se presenta un resumen de dichas herramientas de software que fueron empleadas para dar cumplimiento a los objetivos del presente TT.

TABLA V

LENGUAJE DE PROGRAMACIÓN, ALGORITMOS Y HERRAMIENTAS DE SOFTWARE NECESARIOS PARA LA EJECUCIÓN DE LA METODOLOGÍA KDT

Lenguaje de programación	<ul style="list-style-type: none"> • Python
Algoritmos	<ul style="list-style-type: none"> • Naive Bayes • Support Vector Machines (SVM) • Logistic Regression
Herramientas de software	<ul style="list-style-type: none"> • Spyder IDE • Google Colab
Bibliotecas	<ul style="list-style-type: none"> • Twitter Scraper • Pandas • NLTK • Scikit-Learn • Imbalanced-Learn (SMOTE) • RegEx • JobLib • Matplotlib • GoogleTrans

Objetivo 2: Aplicar metodología para el análisis de sentimientos

Tarea 1: Identificar el intervalo de tiempo más conveniente para delimitar la búsqueda y extracción de los tuits

De acuerdo a Migración del Ministerio de Gobierno del Ecuador [70], en el periodo del 2016 a 2019 se han registrado más de 300 mil migrantes de nacionalidad venezolana que se han quedado a vivir en el país. A razón de esto se consideró que el rango más factible para la recolección de datos en Twitter sea este, de enero de 2016 a diciembre de 2019.

Tarea 2: Ejecutar las fases de la metodología seleccionada en el primer objetivo específico

De acuerdo a Elmenreich [34], la metodología KDT consta de seis etapas principales para realizar el proceso de descubrimiento de conocimiento en texto, las mismas que están representadas en la Fig. 6.

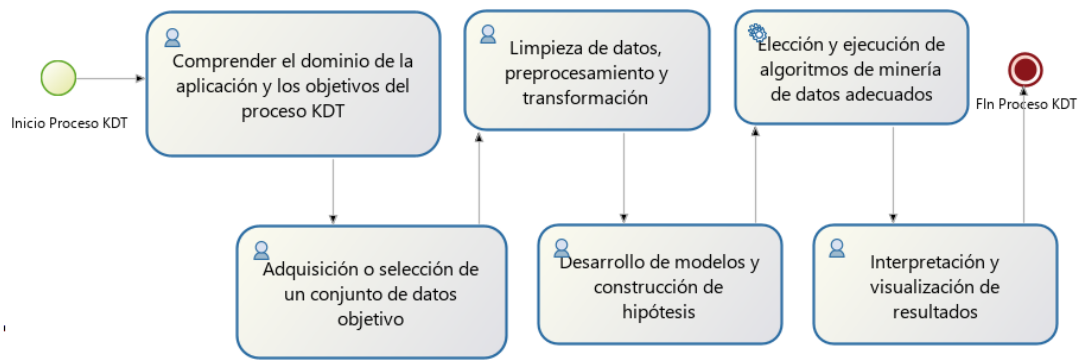


Fig. 6 Representación de las etapas de la metodología KDT

Cada etapa conllevó a realizar una serie de tareas adicionales a las previstas, fueron realizadas principalmente con el objetivo de mejorar los resultados. Dichas tareas se presentan a continuación en la Fig. 7, están ordenadas de acuerdo a las etapas de la metodología KDT.

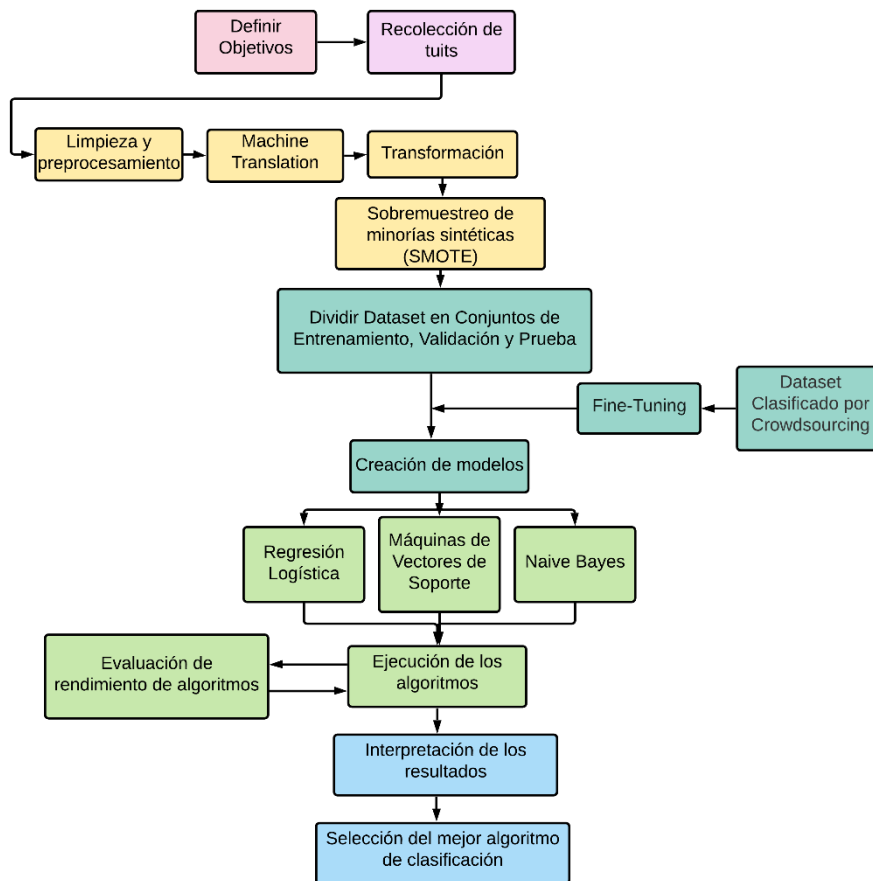


Fig. 7 Proceso de la metodología KDT que implementé

A continuación, se presentan los resultados obtenidos para cada una de las fases de la metodología KDT, realizada para la determinación de la existencia de mensajes xenófobos en la red social Twitter.

1. Comprender el dominio de la aplicación y los objetivos del proceso KDT

Para comprender el dominio de la aplicación se definieron una serie de términos que aportaron a entender de mejor manera los conceptos que están entorno a cada una de las herramientas de software, los algoritmos, las técnicas y el lenguaje de programación que fue necesario para realizar el presente proceso KDT. La conceptualización de estos términos se presenta en la sección de Revisión de literatura (ver Conceptos preliminares).

Por otra parte, según a los objetivos que se plantearon en el presente TT, también se realizaron los siguientes objetivos para el presente proceso KDT.

- Determinar y analizar los sentimientos de un conjunto de datos recolectados de la red social Twitter.
- Interpretar los resultados obtenidos por los algoritmos ejecutados en la fase de minería de datos.

2. Adquisición o selección de un conjunto de datos objetivo

Recolección de datos

A través de la librería Twitter Scraper en Python, se pudieron obtener gran cantidad de tuits (13474, ver [Repositorio](#)⁸), dichas consultas se realizaron sin verse afectada por las restricciones de las API Search, REST o Streaming de Twitter, las mismas que tienen un límite en el número de solicitudes y en el periodo de tiempo (hasta hace 7 días) para recolectar las publicaciones que mantiene dicha red social.

Mediante la recolección de los tuits, se formó un dataset el cual fue el principal insumo para trabajar durante el desarrollo de las siguientes etapas.

El dataset inicial contiene información sin tratar o datos en bruto, es decir, aún no es factible aplicar modelos de algoritmos para el análisis de sentimientos. Cada observación del dataset contenía características no relevantes, como su identificador, nombre de usuario, cantidad de me gusta, etc. en la TABLA VI se presentan todas las características de cada tuit obtenido; además, en el Anexo 9 se presenta parte del dataset con la información aún sin procesar.

⁸ https://github.com/raulrrv/Deteccion_Xenofobia_TT/blob/master/data/dataset_2_inicial.xlsx

TABLA VI
LISTA DE CARACTERÍSTICAS DE CADA TUIT OBTENIDO

Características de los tuits
screen_name
username
user_id
tweet_id
tweet_url
timestamp
timestamp_epochs
text
text_html
links
hashtags
has_media
img_urls
video_url
likes
retuits
replies
is_replied
is_reply_to
parent_tweet_id
reply_to_users

De las cuales sólo se consideró relevante la característica text, ya que este campo es suficiente para dar respuesta a la pregunta de investigación del presente TT (¿Existen tuits con contenido xenófobo hacia los inmigrantes venezolanos en Ecuador?).

Previo al desarrollo de modelos, se aplicó Machine Translation (traducción automática) y la limpieza del dataset con el propósito de ofrecerle como entrada al modelo solo los datos más relevantes para su correcta aplicación. Dicho proceso se realizó en la siguiente etapa.

3. Limpieza de datos, preprocesamiento y transformación

En esta sección se realizó la limpieza, preprocesamiento y transformación de los datasets, tanto el que ha sido previamente clasificado por crowdsourcing (lo llamaremos dataset 1) y el recolectado en el contexto de venezolanos inmigrantes en Ecuador (dataset 2).

Limpieza y preprocesamiento de datos

- **Dataset 1 (previamente clasificado por crowdsourcing)**

Este dataset contiene el texto de interés en la característica “tweet”, por lo tanto, se lo tomó para realizar los procesos de esta sección, para lo cual se requiere descartar aquellos caracteres o palabras que no contribuyen al desarrollo del modelo de clasificación.

Se tomó todos los 24783 tuits que forman dicho dataset, para iniciar con su limpieza y preprocesamiento. Mediante la librería RegEx, con el uso de expresiones regulares se eliminaron los textos innecesarios contenidos en cada tweet, las expresiones regulares utilizadas se muestran en la TABLA VII.

TABLA VII
USO DE EXPRESIONES REGULARES

Tipo de texto	Expresión regular
Menciones a usuarios	'@[w\.-]+'
Hashtag	'#[w\.-]+'
Enlaces	'http[s]?://(?:[a-zA-Z][0-9][\$_@.&+])' '[!*\(\),](?:%[0-9a-fA-F][0-9a-fA-F]))+'
Caracteres especiales y Signos de puntuación	'\W'
Exceso de espaciados	'\s+'

- **Dataset 2**

La única característica seleccionada a tratar fue la “text” en donde se encuentra el contenido textual del tuit, para lo cual se requirió descartar aquellos caracteres o palabras que no contribuyen al desarrollo del modelo de clasificación.

Mediante la librería RegEx, también con el uso de las expresiones regulares (ver TABLA VII) se eliminaron los textos innecesarios contenidos en cada tuit. Realizada la limpieza se procedió a eliminar los tuits duplicados.

Transformación

- **Dataset 1 (previamente clasificado por crowdsourcing)**

El presente dataset se utilizó para entrenar los modelos de clasificación, el mismo que de acuerdo a Davidson [4], ha sido etiquetado para tres clases mediante crowdsourcing (colaboración abierta distribuida) realizado por trabajadores de CrowdFlower [71], en la TABLA VIII se extrajo una pequeña muestra de los tuits en inglés clasificados por crowdsourcing. Clases empleadas: 0, 1 y 2 equivalentes a discursos del odio, lenguaje ofensivo y ninguno, respectivamente.

TABLA VIII
MUESTRA DE TUIITS EN INGLÉS CLASIFICADOS POR TÉCNICA CROWDSOURCING

Texto	Clase
Dawg you ever fuck bitch and she start to cry you be confused as shit	Lenguaje ofensivo
Alsarab he's beaner you can tell hes mexican	Discursos del odio
Happy birthday nigga thanks you	Ninguno
How bout them cowboys shut up pussy	Lenguaje ofensivo
Being single isn't an excuse to be hoe	Lenguaje ofensivo
LMFAO hate black people this is why there black people and niggers	Discursos del odio

El dataset de entrenamiento mantenía un desequilibrio en sus clases, como podemos ver en la Fig. 8 , en donde, la clase 1 prevalece considerablemente más que el resto, lo que provoca un sesgo al momento de entrenar los modelos de clasificación.




Fig. 8 Desequilibrio en las clases del dataset 1 de entrenamiento, clasificado por crowdsourcing

Para lo cual fue necesario aplicar una Técnica De Sobremuestreo De Minorías Sintéticas (SMOTE) para sintetizar nuevos ejemplos a partir de ejemplos existentes, es decir, es un tipo de aumento de datos para las clases minoritarias.

Previo a su aplicación, con la ayuda de la librería Scikit-Learn se realizó la transformación de los textos en valores vectorizados para posibilitar su procesamiento. Dicho proceso se realizó mediante el modelo TF-IDF (Término Frecuencia Multiplicado por Frecuencia inversa del Documento), es una estadística numérica simple que se utiliza para determinar la relevancia de un texto en relación con los términos de una consulta de búsqueda.

Durante la aplicación de este modelo de frecuencia de términos se emplearon las stopwords en inglés dadas por la librería NLTK, con el propósito de descartar aquellas palabras poco relevantes para el vocabulario de palabras. Luego de la aplicación de la técnica SMOTE, en la Fig. 9 tenemos los siguientes resultados.




Fig. 9 Equilibrio en las clases del dataset 1 clasificado por crowdsourcing

Se puede observar un equilibrio en cada una de las clases, en donde las clases minoritarias 0 y 2 a través de la técnica SMOTE han creado nuevos ejemplos sintéticos, llegando a igualarse con el número de observaciones de la clase mayoritaria 1, este aumento hasta el punto de igualarse se dio por el ajuste automático asignado para la estrategia de muestreo, así como también se determinó que utilice un total de $k=10$ (número de vecinos), es decir, este proceso consistió en tomar un tuit de forma aleatoria de la clase minoritaria y de entre los k vecinos más cercanos se eligió un vecino seleccionado al azar y se creó un ejemplo sintético en un punto al azar entre los dos ejemplos.

- **Dataset 2**

En la siguiente etapa, para el entrenamiento del modelo se requirió que el dataset que se recolectó (dataset 2) se encuentre también en inglés al igual que el dataset 1, para evitar crear un sesgo entre los tuits recolectados en español, con los tuits de entrenamiento en inglés, por lo tanto, se realizó el proceso de Machine Translation para la traducción al inglés de los tuits recolectados, con la librería GoogleTrans, se realizó con éxito la traducción masiva de los mismos. En este punto se repite la eliminación de los tuits duplicados, quedando un total de 9888 tuits.

Posteriormente para la vectorización de los tuits recolectados se procedió a aplicar el mismo modelo de frecuencia TF-IDF empleado para transformar los tuits del dataset 1, se emplea el mismo modelo de frecuencia con el fin de generar la misma cantidad de características en ambos dataset para su posterior utilización.

En la siguiente etapa se realizó la clasificación del dataset 2, en donde, si se obtiene clases desequilibradas, también se aplica la técnica SMOTE para mantenerlas en equilibrio. Así mismo, recordemos que la recolección de los tuits fue de específicamente acerca de venezolanos inmigrantes en el Ecuador, lo que permite estrechar la amplitud de los discursos del odio del dataset de entrenamiento, es decir, esta clase de discursos del odio se va a limitar a la presencia de xenofobia en los datos, es por eso que durante el ejercicio en el que intervenga el dataset recolectado, a la clase 0 ahora se la considera como xenofobia.

4. Desarrollo de modelos y construcción de hipótesis

La detección de xenofobia estuvo enmarcada en los mensajes que contienen discursos del odio, los mismo que cubren al racismo y el odio a los extranjeros, razón por la cual para la construcción de un modelo como ya se ha mencionado anteriormente, se tomó un dataset ya clasificado previamente por trabajadores de CrowdFlower [71], el mismo que Davidson [4] lo emplea para entrenar modelos de clasificación, en donde su modelo de mejor rendimiento tiene una precisión del 91%, recall 90% y puntuación F1 del 90%. A continuación, en la Fig. 10 podemos observar la matriz de confusión realizada por Davidson [4], en que la clase Hate (discursos del odio) tiene un 44% de errores y 61% de precisión en la clasificación, posiblemente se deba al evidente desequilibrio de las clases, esta hipótesis se confirma creando nuevos modelos de clasificación pero en base al dataset con sus clases equilibradas.




Fig. 10 Matriz de confusión del dataset 1 desequilibrado

Los siguientes modelos han sido entrenados con el dataset que previamente se equilibró sus clases con SMOTE. Así mismo, este dataset equilibrado ha sido la base para crear un modelo inicial para cada algoritmo, es decir, cada modelo contendrá el aprendizaje obtenido del 100% del conjunto de datos del dataset anteriormente mencionado.

Para crear estos modelos base, se tomó el 100% del dataset equilibrado ya que esto aumenta el conjunto de datos de entrenamiento del modelo y por ende mejora su exactitud al momento de realizar las predicciones del dataset 2 (que contiene los mensajes hacia los inmigrantes venezolanos en Ecuador).

Antes de crear y aplicar los modelos para el dataset 2, se inició creando un modelo del dataset 1 equilibrado para posteriormente comparar con los resultados del mismo dataset pero con las clases desequilibradas (resultados obtenidos por Davidson [4]).

De acuerdo a Leonardo et al. [59], una buena práctica en Machine Learning es la de subdividir nuestro conjunto de datos de entrada en un conjunto de entrenamiento y otro de test (que no se utiliza durante el entrenamiento y por lo tanto la máquina desconoce), en donde se recomienda utilizar el 80% de los datos para entrenamiento y 20% para el test, dichas muestras se tomaron de manera aleatoria mediante la librería Scikit-Learn.




Fig. 11 División del dataset 1 equilibrado

Para saber el desempeño real de un modelo antes de aplicarlo, se tiene una solución muy común, es la de usar el conjunto de entrenamiento para entrenar y evaluar al mismo tiempo, lo que se llama la validación cruzada, consiste en dividir el conjunto de entrenamiento en k partes iguales, si k=5 entonces se entrena el modelo con las cuatro primeras partes y se prueba con la quinta, luego se entrena con las primeras tres y la quinta y se prueba con cuarta, se repite esto k veces, dejando siempre afuera una parte

para la prueba, luego se promedia el desempeño en cada una y así se obtiene el desempeño esperado [72]. Para las validaciones correspondientes al presente TT se consideró utilizar k=10 (número de pliegues), que es el número de partes en que se va a dividir el conjunto de datos para entrenar y evaluar a los modelos.

A continuación, se realizó la validación cruzada para cada uno de los algoritmos de clasificación.

Modelo de Regresión Logística

- **Modelo de dataset 1 (previamente clasificado por crowdsourcing)**

Mediante la librería Scikit-Learn se empleó la Regresión Logística para la creación del modelo. Así también, a través de la validación cruzada, en la TABLA IX se presentan los resultados obtenidos.

TABLA IX
VALIDACIÓN CRUZADA DE MODELO DE REGRESIÓN LOGÍSTICA DATASET 1 EQUILIBRADO

	Puntuación F1
K = 10	0.92135005
	0.9292324
	0.93688589
	0.92685268
	0.93055438
	0.91707027
	0.92394286
	0.92882594
	0.91871388
	0.92234778
Puntuación media	0.925578

De acuerdo a una puntuación F1, se tiene un 93% de precisión del modelo del conjunto de entrenamiento, dicho valor debería asemejarse al aplicar dicho modelo al conjunto de testing. Estos resultados se obtienen a continuación.

Una vez obtenidas las predicciones, se generó el siguiente reporte de clasificación, con su respectiva matriz de confusión, presentadas en la TABLA X y Fig. 12 respectivamente:

TABLA X

REPORTE DE CLASIFICACIÓN PARA EL MODELO ENTRENAMIENTO DE REGRESIÓN LOGÍSTICA

Clase	Precisión	Recall	F1-Score	Support
0 (Discurso odio)	0.91	0.94	0.92	3792
1 (Ofensivo)	0.96	0.87	0.91	3862
2 (Ninguno)	0.92	0.98	0.95	3860
Accuracy (exactitud)			0.93	11514
Macro AVG	0.93	0.93	0.93	11514
Weighted AVG	0.93	0.93	0.93	11514

**Matriz de confusión del modelo de entrenamiento
Regresión Logística del dataset 1 equilibrado**




Fig. 12 Matriz de confusión del modelo de entrenamiento de Regresión Logística del dataset 1 equilibrado

Con esta puntuación F1 del 93% pudimos corroborar que son correctos los resultados de la validación cruzada en donde también se obtiene una puntuación media del 93%, recordemos que estos resultados fueron obtenidos del modelo realizado con el 80% del dataset y testeado con el 20% restante.

Con este resultado se afirmó que el dataset clasificado mediante crowdsourcing es confiable para ser aplicado a nuestro dataset 2 (no etiquetado que contiene mensajes

hacia inmigrantes venezolanos en Ecuador). Para mejorar la precisión del modelo se aumentó el conjunto de datos para entrenarlos, del 80% al 100%. Para la posterior utilización en la siguiente etapa, a este nuevo modelo se lo exportó como archivo pkl mediante la librería JobLib.

Modelo de Máquinas de Soporte Vectorial (SVM)

- **Modelo de dataset 1 (previamente clasificado por crowdsourcing)**

Mediante la librería Scikit-Learn se empleó el algoritmo Máquinas de Soporte Vectorial para la creación del modelo. Así mismo, para hacer una comprobación más acertada se utilizó la validación cruzada, en la TABLA XI se presentan los resultados obtenidos.

TABLA XI
VALIDACIÓN CRUZADA DE MODELO DE SVM DATASET 1 EQUILIBRADO

K = 10	Puntuación F1
	0.93181311
	0.93646192
	0.9270139
	0.93629634
	0.93528361
	0.93629947
	0.93730685
	0.93563019
	0.93464381
	0.93317257
Puntuación media	0.934392
Puntuación estándar	0.002916

De acuerdo a una puntuación F1 se tuvo un 93% de precisión del modelo del conjunto de entrenamiento, este valor se asemejó como se esperaba al valor resultante del conjunto de pruebas o testing.

Posteriormente, se aplicó el modelo al conjunto de testing y una vez obtenidas las predicciones, se generó el siguiente reporte de clasificación, con su respectiva matriz de confusión, presentadas en la TABLA XII y Fig. 13 respectivamente:

TABLA XII
 REPORTE DE CLASIFICACIÓN PARA EL MODELO ENTRENAMIENTO DE SVM

Clase	Precisión	Recall	F1-Score	Support
0 (Discurso odio)	0.90	0.96	0.93	3792
1 (Ofensivo)	0.98	0.86	0.92	3862
2 (Ninguno)	0.94	0.99	0.96	3860
Accuracy (exactitud)			0.94	11514
Macro AVG	0.94	0.94	0.94	11514
Weighted AVG	0.94	0.94	0.94	11514

Matriz de confusión del modelo de entrenamiento de SVM con el conjunto de test




Fig. 13 Matriz de confusión del modelo de entrenamiento de SVM del dataset 1 equilibrado

Con esta puntuación F1 del 94% se corroboró que son muy semejantes los resultados de la validación cruzada en donde se obtiene una puntuación media del 93%, recordemos que estos resultados fueron obtenidos del modelo realizado con el 80% del dataset y testeado con el 20% restante.

Con este resultado se afirmó que el dataset clasificado mediante crowdsourcing es confiable para ser aplicado a nuestro dataset 2 (no etiquetado que contiene mensajes hacia inmigrantes venezolanos en Ecuador). Para un fine-tuning (ajuste fino) en la precisión del modelo se aumentó el conjunto de datos para entrenarlo del 80% al 100%.

Para su posterior utilización en la siguiente etapa, a este nuevo modelo se lo exportó como archivo pkl mediante la librería JobLib.

Modelo de Naive Bayes

- **Modelo de dataset 1 (previamente clasificado por crowdsourcing)**

Mediante la librería Scikit-Learn se empleó el algoritmo Naive Bayes para la creación del modelo, donde mediante la aplicación de una validación cruzada, se precisó el rendimiento del modelo a utilizar. En la TABLA XIII se presentan los resultados obtenidos de la validación cruzada al dataset 1 equilibrado.

TABLA XIII
VALIDACIÓN CRUZADA DE MODELO DE NAIVE BAYES DATASET 1 EQUILIBRADO

K = 10	Puntuación F1
	0.88396611
	0.89241341
	0.87646056
	0.88463818
	0.88629754
	0.88850958
	0.87964417
	0.88810902
	0.88949099
	0.87756313
Puntuación media	0.884709
Puntuación estándar	0.005060

De acuerdo a una puntuación F1, se tuvo un 88% de precisión del modelo del conjunto de datos de entrenamiento mediante una validación cruzada, desde ya se aprecia que este algoritmo tuvo en menor rendimiento, aun así, se continuó ejecutando las siguientes pruebas.

Se procedió a realizar predicciones al conjunto de datos de testing para terminar de medir el rendimiento del modelo. Una vez obtenidas las predicciones, se generó el siguiente reporte de clasificación, con su respectiva matriz de confusión, presentadas en la TABLA XIV y Fig. 14 respectivamente:

TABLA XIV

REPORTE DE CLASIFICACIÓN PARA EL MODELO ENTRENAMIENTO DE NAIVE BAYES

Clase	Precisión	Recall	F1-Score	Support
0 (Discurso odio)	0.85	0.94	0.89	3792
1 (Ofensivo)	0.90	0.82	0.85	3862
2 (Ninguno)	0.93	0.91	0.92	3860
Accuracy (exactitud)			0.89	11514
Macro AVG	0.89	0.89	0.89	11514
Weighted AVG	0.89	0.89	0.89	11514

Matriz de confusión del modelo de entrenamiento de Navie Bayes con el conjunto de test




Fig. 14 Matriz de confusión del modelo de entrenamiento de Naive Bayes del dataset 1 equilibrado

Con esta puntuación F1 del 89% se pudo corroborar que son muy semejantes los resultados de la validación cruzada en donde se obtuvo una puntuación media del 88%, recordemos que estos resultados fueron obtenidos del modelo realizado con el 80% del dataset y testeado con el 20% restante.

Con este resultado se pudo afirmar que el dataset clasificado mediante crowdsourcing es confiable para ser aplicado a nuestro dataset 2 (no clasificado que contiene mensajes hacia inmigrantes venezolanos en Ecuador). Así mismo, se recuerda que para el afinamiento en la precisión del modelo se ha aumentado el conjunto de datos para entrenarlo del 80% al 100%. Para la posterior utilización en la siguiente etapa, a este

nuevo modelo se lo exportó como archivo pkl mediante la librería JobLib.

5. Elección y ejecución de algoritmos de minería de datos adecuados

Elección de algoritmos

Los algoritmos seleccionados durante la revisión bibliográfica han sido:

- Regresión Logística
- Máquinas de Soporte Vectorial (SVM)
- Naive Bayes

Ejecución de algoritmos

Regresión Logística

Mediante la aplicación de fine-tuning al modelo de regresión logística tratado anteriormente, en esta etapa se lo importó (mediante la librería JobLib) para realizar las predicciones correspondientes al conjunto de datos de interés, es decir, como datos de entrada se tuvo a los tuits recolectados en la segunda fase de la metodología KDT (dataset 2), los mismos que mediante Machine Translation fueron traducidos al inglés para su correcto procesamiento, así como también vectorizados con la técnica de frecuencia de término TF-IDF. La clasificación del dataset 2 se presenta a continuación, en la Fig. 15.




Fig. 15 Clasificación del dataset 2 (con mensajes hacia inmigrantes venezolanos en Ecuador)

Las clases fueron nombradas de la siguiente manera:

Clase 0 para sentimientos Xenófobos, con 654 tuits clasificados.

Clase 1 para sentimientos de Lenguaje ofensivo. con 2000 tuits clasificados.

Clase 2 para otros sentimientos, con 7234 tuits clasificados.

La actualización de los nombres de las clases se dio a que el nuevo dataset fue recopilado específicamente con tuits dirigidos a venezolanos que radican en el Ecuador, en donde el amplio campo de los discursos del odio se reduce a los específicos de rechazo a los extranjeros (xenofobia) y la clase anteriormente llamada “Ninguno” se la cambió por “Otro” ya que representa mejor el campo de sentimientos que abarca esta categoría.

Ahora se creó un modelo para este dataset que es el de nuestro interés analizar, pero, como se puede observar en la Fig. 15, las clases están completamente desequilibradas, lo que no fue nada favorable para el entrenamiento del modelo, por lo tanto, previo a su creación se aplicó la técnica STOME para conseguir el equilibrio deseado en las clases y por lo tanto afinar la precisión del modelo.




Fig. 16 Dataset 2 clasificado y equilibrado por modelo de regresión logística

Se generó un nuevo dataset con 21702 observaciones con datos sintéticos. Una vez que se obtuvo el nuevo dataset equilibrado, se procedió a crear el modelo de Regresión Logística, donde también se empleó el 80% de los datos para entrenamiento y 20% para el test, dichas muestras se tomaron de manera aleatoria mediante la librería Scikit-Learn. En la Fig. 17, se representa la división del dataset en los conjuntos de

entrenamiento y test.




Fig. 17 División de dataset 2 equilibrado, en conjunto de entrenamiento y test

Antes de crear un nuevo modelo de regresión logística entorno al dataset 2, se obtuvo un conjunto de datos para validar dicho modelo, este conjunto de validación se lo obtuvo de un 20% del conjunto de entrenamiento. El nuevo conjunto de entrenamiento y validación se representa de la siguiente manera (ver Fig. 18):




Fig. 18 División de dataset 2 equilibrado, en conjunto de entrenamiento y validación

Con esta subdivisión del conjunto principal de entrenamiento, se obtuvieron dos nuevos conjuntos de menores dimensiones tanto de entrenamiento como de validación; el objetivo de esto fue crear un nuevo modelo de regresión logística a partir de este subconjunto de entrenamiento el mismo que fue útil inicialmente para validar la precisión

del modelo y posteriormente para realizar predicciones al conjunto de prueba (datos que desconoce el modelo).

El modelo fue creado solo a partir del subconjunto de entrenamiento, para posteriormente realizar las predicciones al conjunto de validación y al conjunto principal de test. Una vez obtenidas las predicciones, se generó el siguiente reporte de clasificación, con su respectiva matriz de confusión (ver TABLA XV y Fig. 19, respectivamente):

TABLA XV
 REPORTE DE CLASIFICACIÓN PARA EL MODELO DE REGRESIÓN LOGÍSTICA APLICADO AL CONJUNTO DE VALIDACIÓN

Clase	Precisión	Recall	F1-Score	Support
0 (Xenófobo)	0.94	1.00	0.97	1146
1 (Ofensivo)	0.96	0.95	0.96	1144
2 (Otro)	0.96	0.92	0.94	1183
Accuracy (exactitud)			0.96	3473
Macro AVG	0.96	0.96	0.96	3473
Weighted AVG	0.96	0.96	0.95	3473

Matriz de confusión del modelo de entrenamiento de Regresión Logística con el conjunto de validación




Fig. 19 Matriz de confusión del modelo de Regresión Logística aplicado al conjunto de validación

Se obtuvo una puntuación F1 del 96% en su capacidad de predicción, modelo realizado con el subconjunto de entrenamiento (80%) y con predicciones al conjunto de datos de validación (20%), es decir, aún corresponde continuar con la predicción y aplicar el modelo al conjunto de datos que desconoce (al 20% del conjunto de test).

Así mismo, una vez obtenidas las predicciones, se generó el siguiente reporte de clasificación, con su respectiva matriz de confusión (ver TABLA XVI y Fig. 20, respectivamente):

TABLA XVI
 REPORTE DE CLASIFICACIÓN PARA EL MODELO DE REGRESIÓN LOGÍSTICA APLICADO AL CONJUNTO DE TEST

Clase	Precisión	Recall	F1-Score	Support
0 (Xenófobo)	0.94	0.99	0.97	1493
1 (Ofensivo)	0.96	0.95	0.95	1443
2 (Otro)	0.96	0.91	0.93	1405
Accuracy (exactitud)			0.95	4341
Macro AVG	0.95	0.95	0.95	4341
Weighted AVG	0.95	0.95	0.95	4341

Matriz de confusión del modelo de entrenamiento de Regresión Logística con el conjunto de test




Fig. 20 Matriz de confusión del modelo de Regresión Logística validado con el conjunto principal de Test

Se obtuvo una puntuación F1 del 95% en su capacidad de predicción, modelo realizado con el mismo subconjunto de entrenamiento (80%) y aplicado esta vez con el conjunto de test (20%). Mediante esta validación del dataset 2 ya clasificado se creó un modelo final capaz de clasificar nuevos tuits con un margen menor de error. A continuación, en la TABLA XVII se presenta un pequeño conjunto de textos que han sido clasificados para verificar manualmente la precisión de las predicciones, en este caso corresponde para al algoritmo de Regresión Logística.

TABLA XVII
EJEMPLOS DE LAS PREDICCIONES DE REGRESIÓN LOGÍSTICA

Texto Original	Machine Translation	Predicción
Venezolano no te queremos en nuestro país	Venezuelan we don't want you in our country	0: Xenofobia
Maldito venezolano	Damn venezuelan	1: Ofensivo
Los venezolanos son bienvenidos	Venezuelans are welcome	2: Ninguno
Venezuela es un país grande	Venezuela is a big country	2: Ninguno
Los venezolanos no son bienvenidos en ningún país.	Venezuelans are not wanted in any country	2: Ninguno
Ya es hora de que salgan de mi país	It is time for them to leave my country	0: Xenofobia

Por otra parte, mediante el entrenamiento del 100% del dataset 2 equilibrado se obtuvo un modelo final⁹ de regresión logística el mismo que a través de la librería Scikit-Learn fue exportado para su utilización en posteriores investigaciones.

Máquinas de Soporte Vectorial (SVM)

Para la ejecución del presente algoritmo, fue importado el modelo de SVM anteriormente creado en la etapa de desarrollo de modelos (importación realizada con JobLib).

Como datos de entrada se tuvo a los tuits recolectados en la segunda fase de la metodología KDT (dataset 2), los mismos que ya fueron traducidos al inglés para su correcto procesamiento (Machine Translation), también fueron vectorizados con la técnica de frecuencia de término TF-IDF. Finalmente, en la Fig. 21 se presentan los resultados de la clasificación del dataset 2.

⁹

https://github.com/raulrrv/Deteccion_Xenofobia_TT/blob/master/modelo/modelo_regresionlog_final.pkl




Fig. 21 Clasificación del dataset 2 por modelo de SVM

Las clases fueron nombradas de la siguiente manera:

Clase 0 para sentimientos Xenófobos, con 706 tuits clasificados.

Clase 1 para sentimientos de Lenguaje ofensivo. con 1133 tuits clasificados.

Clase 2 para otros sentimientos, con 8049 tuits clasificados.

Ahora se debió crear un modelo para este dataset que es de nuestro interés analizar, pero, como se puede observar en la Fig. 21, las clases están completamente desequilibradas, lo que no es nada favorable para el entrenamiento del modelo, por lo tanto, previo a su creación se aplicó la técnica STOME para conseguir el equilibrio deseado en las clases, como se muestra en la Fig. 22. Resultando también un modelo mejor ajustado.




Fig. 22 Dataset 2 clasificado y equilibrado por modelo de SVM

Se generó un nuevo dataset con 24147 observaciones con datos sintéticos. Una vez obtenido el nuevo dataset equilibrado, se procedió a crear el modelo de Máquina de Soporte Vectorial, donde también se empleó el 80% de los datos para entrenamiento y 20% para el test, como se muestra en la Fig. 23, dichas muestras se tomaron de manera aleatoria mediante la librería Scikit-Learn.

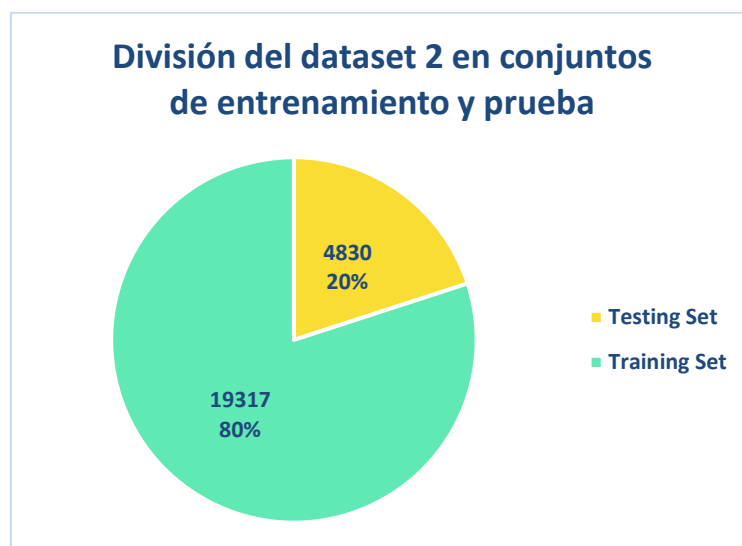


Fig. 23 División de dataset 2 clasificado (SVM) y equilibrado, en conjunto de entrenamiento y test

Antes de crear un nuevo modelo de Máquinas de Soporte Vectorial entorno al dataset 2, se tuvo que tener un conjunto de datos para validar dicho modelo, este conjunto de validación se lo obtuvo de un 20% del conjunto de datos de entrenamiento.

El nuevo conjunto de entrenamiento y validación para SVM se representa de la siguiente manera (ver Fig. 24):




Fig. 24 División de dataset 2 clasificado (SVM) y equilibrado, en conjunto de entrenamiento y validación

Con esta subdivisión del conjunto principal de entrenamiento, se obtuvo dos nuevos conjuntos de menores dimensiones tanto de entrenamiento como de validación; el objetivo de esto fue crear un nuevo modelo de SVM a partir de este subconjunto de entrenamiento el mismo que fue útil inicialmente para validar la precisión del modelo y posteriormente para realizar predicciones al conjunto de prueba (datos que desconoce el modelo).

El modelo fue creado solo a partir del subconjunto de entrenamiento, para posteriormente realizar las predicciones al conjunto de validación y al conjunto principal de test. Una vez obtenidas las predicciones, se generó el siguiente reporte de clasificación, con su respectiva matriz de confusión (ver TABLA XVIII y Fig. 25, respectivamente).

TABLA XVIII
 REPORTE DE CLASIFICACIÓN PARA EL MODELO DE MÁQUINAS DE SOPORTE VECTORIAL
 APLICADO AL CONJUNTO DE VALIDACIÓN

Clase	Precisión	Recall	F1-Score	Support
0 (Xenófobo)	0.97	1.00	0.98	1252
1 (Ofensivo)	0.97	0.99	0.98	1305
2 (Otro)	0.99	0.94	0.97	1307
Accuracy (exactitud)			0.98	3864
Macro AVG	0.98	0.98	0.98	3864
Weighted AVG	0.98	0.98	0.98	3864

Matriz de confusión del modelo de entrenamiento de SVM con el conjunto de validación

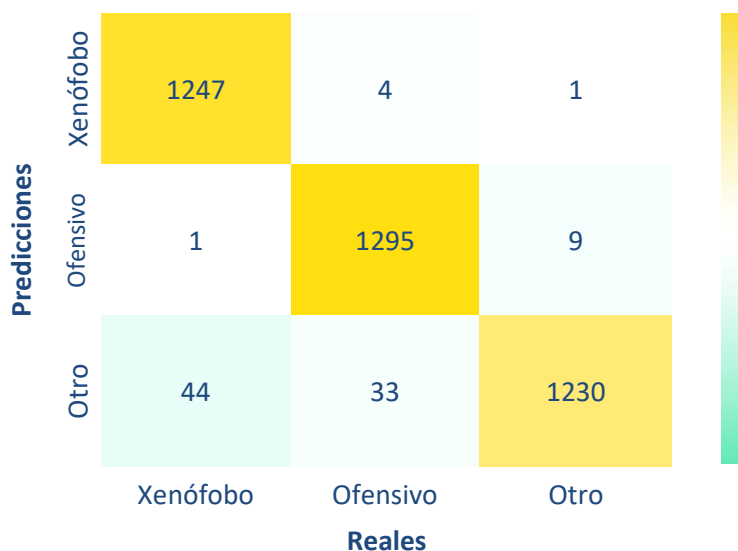


Fig. 25 Matriz de confusión del modelo de SVM aplicado al conjunto de validación

Se obtuvo una puntuación F1 del 98% en su capacidad de predicción, modelo realizado con el subconjunto de entrenamiento (80%) y con predicciones al conjunto de datos de validación (20%), seguidamente se aplicó el modelo para realizar predicciones al conjunto de datos que desconoce (al 20% del conjunto de test).

Así mismo, una vez obtenidas las predicciones, se generó el siguiente reporte de clasificación, con su respectiva matriz de confusión (ver TABLA XIX y Fig. 26, respectivamente):

TABLA XIX
 REPORTE DE CLASIFICACIÓN PARA EL MODELO DE MÁQUINAS DE SOPORTE VECTORIAL
 APLICADO AL CONJUNTO DE TEST

Clase	Precisión	Recall	F1-Score	Support
0 (Xenófobo)	0.97	1.00	0.98	1710
1 (Ofensivo)	0.97	0.99	0.98	1572
2 (Otro)	0.99	0.94	0.96	1548
Accuracy (exactitud)			0.98	4830
Macro AVG	0.98	0.98	0.98	4830
Weighted AVG	0.98	0.98	0.98	4830

Matriz de confusión del modelo de entrenamiento de SVM con el conjunto de test




Fig. 26 Matriz de confusión del modelo de SVM validado con el conjunto principal de Test

Se obtuvo una puntuación F1 del 98% en su capacidad de predicción, modelo realizado con el mismo subconjunto de entrenamiento (80%) y aplicado esta vez con el conjunto de test (20%). Mediante esta validación del dataset 2 clasificado entorno a los mensajes xenófobos se creó un modelo final capaz de clasificar nuevos tuits con un margen menor de error. A continuación, en la TABLA XX se presenta un pequeño conjunto de textos que fue clasificado para verificar manualmente la precisión de las predicciones, en este caso corresponde para el algoritmo de Máquinas de Soporte Vectorial.

TABLA XX
EJEMPLOS DE LAS PREDICCIONES DE MÁQUINAS DE SOPORTE VECTORIAL

Texto Original	Machine Translation	Predicción
Venezolano no te queremos en nuestro país	Venezuelan we don't want you in our country	0: Xenofobia
Maldito venezolano	Damn venezuelan	1: Ofensivo
Los venezolanos son bienvenidos	Venezuelans are welcome	2: Ninguno
Venezuela es un país grande	Venezuela is a big country	2: Ninguno
Los venezolanos no son bienvenidos en ningún país.	Venezuelans are not wanted in any country	2: Ninguno
Ya es hora de que salgan de mi país	It is time for them to leave my country	2: Ninguno

Por otra parte, mediante el entrenamiento del 100% del dataset 2 equilibrado se obtuvo un modelo final¹⁰ de Máquinas de Soporte Vectorial el mismo que a través de la librería Scikit-Learn se ha exportado para su utilización en posteriores investigaciones.

Naive Bayes

Para la ejecución del presente algoritmo, se importó el modelo anteriormente creado de Naive Bayes (importación realizada con JobLib).

De la misma manera, como datos de entrada fueron los tuits recolectados en la segunda fase de la metodología KDT (dataset 2), los mismos que ya fueron traducidos al inglés y vectorizados con la técnica de frecuencia de término TF-IDF. La clasificación del dataset 2 mediante Naive Bayes se presenta a continuación, en la Fig. 27.




Fig. 27 Clasificación del dataset 2 por modelo de Naive Bayes

Las clases fueron nombradas de la siguiente manera:

Clase 0 para sentimientos Xenófobos, con 350 tuits clasificados.

Clase 1 para sentimientos de Lenguaje ofensivo. con 6130 tuits clasificados.

Clase 2 para otros sentimientos, con 3408 tuits clasificados.

Como se puede observar en la Fig. 27, las clases están completamente desequilibradas, lo que no fue nada favorable para el entrenamiento del modelo, por lo tanto, previo a su creación se aplicó la técnica STOME para conseguir el equilibrio deseado en las clases, como se muestra en la Fig. 28, además que se mejora el afinamiento del modelo.

10

https://github.com/raulrrv/Deteccion_Xenofobia_TT/blob/master/modelo/modelo_svm_final.pkl




Fig. 28 Dataset 2 clasificado y equilibrado por modelo de Naive Bayes

Se generó un nuevo dataset con 18390 observaciones con datos sintéticos. Una vez obtenido el nuevo dataset equilibrado, se procedió a crear el modelo de Naive Bayes, donde también se empleó el 80% de los datos para entrenamiento y 20% para el test, como se muestra en la Fig. 29, dichas muestras se tomaron de manera aleatoria mediante la librería Scikit-Learn.




Fig. 29 División de dataset 2 clasificado (Naive Bayes) y equilibrado, en conjunto de entrenamiento y test

Antes de crear un nuevo modelo de Naive Bayes entorno al dataset 2, se debió tener un conjunto de datos para validar dicho modelo, este conjunto de validación se lo obtuvo de un 20% del conjunto de entrenamiento.

El nuevo conjunto de entrenamiento y validación se representa de la siguiente manera (ver Fig. 30):




Fig. 30 División de dataset 2 clasificado (SVM) y equilibrado, en conjunto de entrenamiento y validación

Con esta subdivisión del conjunto principal de entrenamiento, se obtuvo dos nuevos conjuntos de menores dimensiones tanto de entrenamiento como de validación; el objetivo de esto fue crear un nuevo modelo de Naive Bayes a partir de este subconjunto de entrenamiento el mismo que fue útil inicialmente para validar la precisión del modelo y posteriormente para realizar predicciones al conjunto de los datos de prueba (datos que desconoce el modelo). El modelo fue creado solo a partir del subconjunto de entrenamiento, para posteriormente realizar las predicciones al conjunto de validación y al conjunto principal de test. Una vez obtenidas las predicciones, se generó el siguiente reporte de clasificación, con su respectiva matriz de confusión (ver TABLA XXI y Fig. 31, respectivamente).

TABLA XXI

REPORTE DE CLASIFICACIÓN PARA EL MODELO DE NAIVE BAYES APLICADO AL CONJUNTO DE VALIDACIÓN

Clase	Precisión	Recall	F1-Score	Support
0 (Xenófobo)	0.92	0.99	0.96	1008
1 (Ofensivo)	0.88	0.82	0.85	905
2 (Otro)	0.87	0.85	0.86	985
Accuracy (exactitud)			0.89	2943
Macro AVG	0.89	0.89	0.89	2943
Weighted AVG	0.89	0.89	0.89	2943

Matriz de confusión del modelo de entrenamiento de Navie Bayes con el conjunto de validación




Fig. 31 Matriz de confusión del modelo de Naive Bayes aplicado al conjunto de validación

Se obtuvo una puntuación F1 del 89% en su capacidad de predicción, modelo realizado con el subconjunto de entrenamiento (80%) y con predicciones al conjunto de datos de validación (20%), es decir, aún se debió continuar con la predicción y aplicación del modelo al conjunto de datos que desconoce (al 20% del conjunto de test). Una vez obtenidas las predicciones, se generó el siguiente reporte de clasificación, con su respectiva matriz de confusión (ver TABLA XXII y Fig. 32):

TABLA XXII

REPORTE DE CLASIFICACIÓN PARA EL MODELO DE NAIVE BAYES APLICADO AL CONJUNTO DE TEST

Clase	Precisión	Recall	F1-Score	Support
0 (Xenófobo)	0.91	0.99	0.95	1177
1 (Ofensivo)	0.86	0.80	0.83	1256
2 (Otro)	0.83	0.84	0.83	1245
Accuracy (exactitud)			0.87	3678
Macro AVG	0.87	0.87	0.87	3678
Weighted AVG	0.87	0.87	0.87	3678

Matriz de confusión del modelo de entrenamiento de Navie Bayes con el conjunto de test




Fig. 32 Matriz de confusión del modelo de Naive Bayes validado con el conjunto principal de test

Así también, se obtuvo una puntuación F1 del 98% en su capacidad de predicción, para el algoritmo de Naive Bayes, este modelo fue realizado con el mismo subconjunto de entrenamiento (80%) y aplicado esta vez con el conjunto de test (20%). Mediante esta validación del dataset 2 clasificado entorno a los mensajes xenófobos se creó un modelo final de Naive Bayes capaz de clasificar nuevos tuits con un margen menor de error. A continuación, en la TABLA XXIII se presenta un pequeño conjunto de textos que ha sido clasificado para verificar manualmente la precisión de las predicciones, en este caso corresponde para al algoritmo de Naive Bayes.

TABLA XXIII

EJEMPLOS DE LAS PREDICCIONES DE NAIVE BAYES

Texto Original	Machine Translation	Predicción
Venezolano no te queremos en nuestro país	Venezuelan we don't want you in our country	1: Ofensivo
Maldito venezolano	Damn venezuelan	1: Ofensivo
Los venezolanos son bienvenidos	Venezuelans are welcome	2: Ninguno
Venezuela es un país grande	Venezuela is a big country	2: Ninguno
Los venezolanos no son bienvenidos en ningún país.	Venezuelans are not wanted in any country	1: Ofensivo
Ya es hora de que salgan de mi país	It is time for them to leave my country	2: Ninguno

Finalmente, mediante el entrenamiento del 100% del dataset 2 equilibrado se obtuvo un modelo final¹¹ de Naive Bayes el mismo que a través de la librería Scikit-Learn se exportó para su utilización en posteriores investigaciones, cabe mencionar que este algoritmo fue el de menor rendimiento durante la clasificación de los tuits.

6. Interpretación y visualización de resultados

Esta etapa se desarrolla en su totalidad a continuación, en el Objetivo 3 que consiste en la interpretación de los resultados obtenidos.

¹¹https://github.com/raulrv/Deteccion_Xenofobia_TT/blob/master/modelo/modelo_naviebayes_final.pkl

Objetivo 3: Interpretar los resultados obtenidos en el análisis de sentimientos.

En esta sección se analizaron e interpretaron los resultados obtenidos durante el entrenamiento y ejecución de los modelos de algoritmos de clasificación supervisados., El análisis estuvo dado principalmente entorno a métricas de rendimiento para el aprendizaje automático, que de acuerdo a Deng y Luque et al. [27] [28] se pueden definir una serie de medidas de desempeño de clasificación basadas en la matriz de confusión. Estas medidas son: Exactitud, Precisión, Exhaustividad y Puntuación F1, dichas métricas han sido aplicadas a través de la librería Scikit-Learn y los resultados se presentaron en base a la matriz de confusión y la puntuación F1 (incluye la exactitud, precisión y exhaustividad).

Tarea 1: Analizar e identificar los mejores algoritmos para el análisis de sentimientos

A través de la aplicación de los modelos de algoritmos de clasificación, se realizó la predicción o clasificación de un conjunto de tuits dirigidos a la población inmigrante venezolana radicada en Ecuador, en la que se aplicaron los tres algoritmos que de acuerdo a la revisión bibliográfica son los más relevantes, estos son:

- Regresión Logística
- Máquinas de Soporte Vectorial (SVM)
- Naive Bayes

A continuación, en la Fig. 33 se plasman los resultados de las matrices de confusión obtenidas con los conjuntos de prueba para medir la eficiencia de cada modelo.




Fig. 33 Precisión global de la matriz de confusión de cada algoritmo

Analizado la precisión global de cada matriz de confusión, se puede observar que el resultado de Naive Bayes con un 87,1% es la que difiere notablemente, teniendo un mayor número de falsos positivos y negativos. Dicho algoritmo al igual que el resto fue comprobado mediante una validación cruzada de 10 pliegues, permitiendo obtener la media de las 10 puntuaciones de precisión.

La media de precisión para cada algoritmo es la siguiente:

- Regresión Logística con un 92,5% de precisión
- Máquinas de Soporte Vectorial con un 93,4% de precisión
- Naive Bayes con un 88,4% de precisión

Los resultados obtenidos en la validación cruzada en teoría son los valores más cercanos a la realidad, eso se lo confirmó aplicando el modelo para la predicción de un conjunto de test, lo que dio cifras similares a las arrojadas por la validación cruzada, en donde, de acuerdo a cada modelo se obtuvieron las siguientes puntuaciones F1.

- Regresión Logística con un 93% de puntuación F1
- Máquinas de Soporte Vectorial con un 94% de puntuación F1
- Naive Bayes con un 89% de puntuación F1

En la Fig. 34 se resumen y representan ambas cifras, la validación cruzada y puntuación F1 de cada algoritmo:




Fig. 34 Rendimiento de los modelos para entrenamiento

De acuerdo al análisis entorno a estas métricas de rendimiento, se identificó a los mejores algoritmos para la clasificación de mensajes xenófobos, dichos algoritmos se presentan en la TABLA XXIV ordenados de manera descendente:

TABLA XXIV
RESULTADOS DE ALGORITMOS

	Algoritmos	Validación cruzada	Puntuación F1
1	Máquinas de Soporte Vectorial	93,4%	94%
2	Regresión Logística	92,5%	93%
3	Naive Bayes	88,4%	89%

El algoritmo de Máquinas de Soporte Vectorial con un 94% de puntuación F1 fue seleccionado como el de mejor rendimiento para el análisis de sentimientos (específicamente xenofobia), siguiéndole de muy cerca con un 93% el algoritmo de Regresión Logística y finalmente Naive Bayes que ha dado el menor rendimiento, pero aún con valores relativamente altos (89%).

Tarea 2: Interpretar los resultados obtenidos

Una vez realizado el entrenamiento de los modelos, fueron aplicados al dataset de interés, es decir, al que contiene mensajes hacia inmigrantes venezolanos en Ecuador, para su clasificación con cada uno de los algoritmos, a continuación, en la Fig. 35 se resumen dichas clasificaciones:




Fig. 35 Clasificación del dataset de acuerdo a cada algoritmo

Así como se dio un bajo rendimiento del modelo de Naive Bayes también generó resultados lejanos a los de Regresión Logística y SVM, causando de esta manera un mayor sesgo, en comparación con la clasificación realizada por los algoritmos ya mencionados que tienen valores similares.

Las cifras resultantes de los tres algoritmos serán promediadas para dar un resultado

final en cuanto al número existente de tuits xenófobos, ofensivos y otros.

TABLA XXV
 MEDIA DE LOS RESULTADOS DE CLASIFICACIÓN

Algoritmos	Xenófobo	Ofensivo	Otro
Regresión Logística	654	2000	7234
Máquinas de Soporte Vectorial	706	1133	8049
Naive Bayes	350	6130	3408
Media / Promedio	570	3088	6230

En la TABLA XXV se pueden observar los resultados de clasificación para cada uno de los algoritmos, cifras que varían entre uno y otro algoritmo, por lo tanto, se obtuvo también la media porcentual general para los tres algoritmos, como se presenta en la Fig. 36:




Fig. 36 Media o Promedio porcentual de los tuits clasificados, de acuerdo a cada sentimiento

Como resultados se obtuvieron:

- Un total de 570 tuits con contenido xenófobo, equivalente a un 5,76%
- Un total de 3088 tuits con lenguaje ofensivo, equivalente a un 31,23%
- Un total de 6230 tuits con otros sentimientos, equivalente a un 63,01%

Por otro lado, cabe destacar que el presente TT, en base a estos resultados de clasificación, entrenó un nuevo modelo para cada algoritmo, con las clases equilibradas,

y con el propósito de obtener un modelo afinado y capaz de clasificar tuits con contenido xenófobo, lo que contribuye para otras investigaciones o trabajos futuros.

Los resultados de las pruebas realizadas para este modelo se resumen en la Fig. 37.




Fig. 37 Resultados del entrenamiento para los nuevos modelos clasificadores del sentimiento xenófobo

Los modelos finales de clasificación fueron entrenados con sus clases equilibradas, para obtener un mejor rendimiento en cada modelo, como se pudo observar en la Fig. 37, se tiene a la Máquinas de Soporte Vectorial con el mejor desempeño con un 98%, el algoritmo de Regresión Logística con un 96% y Naive Bayes con un 89% de puntuación F1.

Tarea 3: Dar contestación a la pregunta de investigación

De acuerdo a los resultados ya analizados, se tiene las siguientes definiciones de la clasificación de cada sentimiento encontrado:

Xenófobos.- según Rodríguez [7], la xenofobia capta el rechazo hacia un conjunto de población inmigrante, lo que supone la denigración y posibles comportamientos discriminatorios. Así mismo, la Psic. Gladys Campoverde mediante una entrevista [73], dio a conocer los principales sentimientos que están asociados con la xenofobia, tales como: el odio, repudio y rechazo a los extranjeros, los mismos que han sido la base para determinar un conjunto más amplio de estos sentimientos (Anexo 10).

Ofensivos. – según Davidson [4], el lenguaje ofensivo se diferencia del contenido xenófobo, porque tienen a contener “malas palabras” y a menudo combinado con un

lenguaje sexista u homofóbico (aversión hacia la homosexualidad), que concretamente llegan a ser de carácter ofensivo hacia los demás.

Otros. – en esta clase se consideran aquellos sentimientos no contemplados o no relacionados con la xenofobia y el lenguaje ofensivo, es decir, pueden ser sentimientos positivos, neutrales u otro sin clasificar.

Según los resultados de clasificación realizada en el presente TT, se ha podido dar respuesta a la pregunta de investigación.

¿Existen tuits con contenido xenófobo hacia los inmigrantes venezolanos en Ecuador?

Hipótesis de investigación: Sí existen tuits con contenido xenófobo hacia los inmigrantes venezolanos en Ecuador.

Respuesta a la pregunta de investigación

Sí existen tuits con contenido xenófobo hacia los inmigrantes venezolanos en Ecuador, con una presencia del 5,76%, lo cual es relativamente bajo en comparación al 31,23% de tuits encontrados con contenido ofensivo hacia ellos, así como también la presencia en un 63% de otros sentimientos.

7. DISCUSIÓN

Para conocer la existencia de xenofobia hacia venezolanos inmigrantes en el Ecuador, se realizó a través de una revisión bibliográfica y la metodología para la minería de textos, a continuación, se detallan los puntos más importantes, así como las limitaciones que se presentaron durante de este proceso, además de las mejoras y aportes que ofrece este TT en relación a otros trabajos relacionados.

1. Desarrollo de la propuesta alternativa

Objetivo 1: Realizar una revisión bibliográfica acerca del análisis de sentimientos en Twitter.

Mediante la realización de la Revisión Sistemática de Literatura de Bárbara Kitchenham, a través de sus fases principales: la planificación de la revisión, realizar la revisión y la revisión de informes, en los trabajos relacionados se pudo determinar los algoritmos que tuvieron los mejores resultados: Regresión Logística, Máquinas de Soporte Vectorial y Naive Bayes fueron los que mayormente destacaron, por tanto, fueron los aplicados en el presente TT.

Así mismo, de acuerdo a los estudios encontrados (ver TABLA I), se identificó los pasos necesarios para realizar el análisis de sentimientos a un conjunto de datos (específicamente textos), con lo cual se determinó emplear la metodología KDT para a través de sus etapas realizar todo el proceso de análisis de sentimientos. En donde fueron necesarias una serie de herramientas de software, librerías, algoritmos y lenguaje de programación (ver TABLA V) para cumplir con la ejecución de cada una de estas etapas, las mismas que han sido recopiladas de cada uno de los trabajos relacionados, seleccionando aquellas que según sus autores han ofrecidos los mejores resultados en cuanto al análisis de sentimientos se refiere.

De esta manera, la revisión bibliográfica (ver Objetivo 1 de Sección Resultados) también ha sido un aporte importante para trabajos futuros, debido a que ya se tiene la base sólida con todos los requerimientos teóricos y de software necesarios para realizar cada una de las etapas de la metodología KDT para el análisis de sentimientos entorno a la detección de tuits xenófobos.

Objetivo 2: Aplicar metodología para el análisis de sentimientos.

En lo que corresponde a las etapas realizadas de la metodología KDT, estas son: comprender el dominio de la aplicación y los objetivos del proceso KDT, adquisición o selección de un conjunto de datos objetivo, limpieza de datos, preprocesamiento y transformación, desarrollo de modelos y construcción de hipótesis, elección y ejecución de algoritmos de minería de datos adecuados, interpretación y visualización de resultados.

Se empleó un conjunto de datos extraídos de Twitter (ver [Repositorio](#)¹²) en el contexto de los inmigrantes venezolanos en Ecuador, en los que se pretendía conocer la existencia de xenofobia; se recuerda que de acuerdo a la revisión bibliográfica realizada, no se encontró investigaciones que analicen y determinen la existencia de xenofobia en tuits, sino solo estudios o trabajos que se asemejan, como es el caso de la investigación de Davidson et al. [4], en la que parten clasificando por medio de crowdsourcing¹³ un dataset con tuits en el contexto de discursos del odio, lenguaje ofensivo y otros sentimientos (ver [Repositorio](#)¹⁴), con el objetivo de crear un modelo de clasificación para realizar predicciones a otros conjuntos de datos, este modelo fue empleado para realizar la clasificación del dataset del presente TT, el mismo que fue mejorado en cuanto a que su modelo tenía deficiencias a razón de un claro desequilibrio en sus clases, esto es un punto débil durante el entrenamiento de un modelo, haciendo ineficiente o de bajo rendimiento en la precisión de sus predicciones, razón por lo cual el presente TT incrementó el número de muestras, creando nuevos datos sintéticos de las clases minoritarias mediante SMOTE (Técnica De Sobremuestreo De Minorías Sintéticas), con lo cual se creó nuevos modelos para cada algoritmo, en la Fig. 38 se presenta los resultados del mejor rendimiento de precisión por parte del estudio de Davidson et al. [4] junto a los resultados del mejor rendimiento por parte del algoritmo de Máquinas de Soporte Vectorial del presente TT.

¹² https://github.com/raulrrv/Deteccion_Xenofobia_TT/blob/master/data/dataset_2_inicial.xlsx

¹³ Crowdsourcing. - es la colaboración o externalización abierta de tareas, en donde trabajadores de un sitio web se encargan de clasificar un conjunto de datos. Cabe recalcar que cada tuit tuvo que haber sido clasificado por al menos tres personas para tomarla como válida a dicha clase [42].

¹⁴ http://github.com/raulrrv/Deteccion_Xenofobia_TT/blob/master/data/dataset_1_clasificado.csv




Fig. 38 Comparativa del rendimiento de los resultados del trabajo relacionado y del presente TT

Los resultados del trabajo relacionado se refieren a la puntuación F1 del modelo más eficiente de Davidson et al. con un 90% de precisión, el cual fue mejorado por el presente TT mediante el equilibrio de sus clases, dando una mejorada puntuación F1 del 94% del mejor modelo, siendo el algoritmo de SVM.

Objetivo 3: Interpretar los resultados obtenidos en el análisis de sentimientos.

Concluidas las etapas de entrenamiento de modelos y ejecución de los algoritmos propuestos, se obtuvo resultados satisfactorios en cuanto a la precisión con que dichos algoritmos alcanzaron a realizar la clasificación, inicialmente se clasificó el dataset 2 (tuits en el contexto de los inmigrantes venezolanos en el Ecuador), por medio de los modelos obtenidos del dataset 1 (clasificado a través de crowdsourcing), con lo cual resultó una clasificación de igual manera desequilibrada en sus clases, es decir, un 5,76% de los tuits fue clasificado como xenófobo, el 31,23% como ofensivo y el 63,01% como otro sentimiento, y no está mal, pero si deseamos obtener un nuevo modelo en base al dataset 2, es recomendable tener suficientes muestras de cada clase, es por eso que en comparación a los trabajos relacionados, se aplicó fine-tuning para obtener mejores modelos gracias al equilibrio de las clases, aplicando la técnica de sobremuestreo de minorías sintéticas (SMOTE), la cual permite crear nuevas muestras sintéticas de las clases minoritarias, una vez aplicada la técnica, con las clases equilibradas se creó nuevos modelos en donde sobresale el algoritmo de Máquinas de Soporte Vectorial con un 96% de puntuación F1, que cabe recalcar fue creado con el conjunto de datos en el contexto de contenido xenófobo en tuits hacia inmigrantes

venezolanos en Ecuador.

Finalmente, se concluyó que sí existen tuits con contenido xenófobo en el Ecuador hacia inmigrantes venezolanos, pero en un bajo porcentaje del 5,76% (dataset de 9888 tuits), y se detectó un 31,23% de tuits con contenido ofensivo hacia ellos.

2. Valoración técnica, económica, ambiental y social

2.1. Valoración técnica

El presente TT se valora técnicamente a razón de las múltiples herramientas de software que fueron utilizadas para que trabajen conjuntamente con el objetivo de determinar la existencia de contenido xenófobo en un conjunto de tuits. Librerías como Scikit-Learn desempeñaron un papel fundamental ya que permitió la aplicación de los algoritmos de clasificación de Regresión Logística, Máquinas de Soporte de Vectores y Naive Bayes, así como también el Kit de Herramientas de Lenguaje Natural (NLTK) que brindó las librerías necesarias para el procesamiento de lenguaje natural, como las stopwords y la representación de estadísticas con demostración gráfica. También destaca la Técnica de Sobremuestreo de Minorías Sintéticas (SMOTE) la que permitió sintetizar nuevos ejemplos para las clases minoritarias, dando como resultado un conjunto de datos con sus clases equilibradas, lo que contribuyó a mejorar el desempeño de los algoritmos aplicados.

2.2. Valoración económica

Para la ejecución del presente TT fueron necesarios ciertos recursos económicos, los mismos que se presentan a continuación, en las TABLA XXVI, TABLA XXVII y TABLA XXVIII:

TABLA XXVI
RECURSOS PARA TALENTO HUMANO

Talento Humano			
Responsable	Número de horas	Costo por hora	Costo total
Tesista	400	\$2.50	\$1,000.00
Director	40	\$10.48	\$419.00
TOTAL			\$1,419.00

TABLA XXVII
RECURSOS TÉCNICOS Y TECNOLÓGICOS

Recursos Técnicos y Tecnológicos			
Recursos de Software			
Nombre		Costo total	
LibreOffice		\$0.00	
Mendeley Desktop		\$0.00	
Google Chrome		\$0.00	
Google Colab		\$0.00	
Spyder IDE		\$0.00	
Python		\$0.00	
Firma electrónica		\$22.40	
SUBTOTAL		\$22.40	
Recursos de Hardware			
Nombre	Cantidad	Costo unitario	Costo total
Laptop	1	\$600.00	\$600.00
SUBTOTAL			\$600.00
TOTAL			\$622.40

TABLA XXVIII
RECURSOS PARA SERVICIOS

Servicios			
Nombre	Meses	Costo unitario	Costo total
Internet	5	\$20.00	\$100.00
TOTAL			\$100.00

De acuerdo a todos los recursos económicos anteriormente presentados, se genera la TABLA XXIX en la que se presenta la sumatoria de cada uno de ellos, con el valor total de los gastos que llevó realizar el presente TT.

TABLA XXIX
TOTALIDAD DE LOS RECURSOS ECÓMICOS

Presupuesto General	
Descripción	Costo total
Talento Humano	\$1,000.00
Recursos Técnicos y Tecnológicos	\$622.40
Servicios	\$100.00
TOTAL	\$1,722.40

2.3. Valoración ambiental

El presente TT se realizó en su totalidad con recursos tecnológicos y digitales que no tienen un mayor impacto al medio ambiente, además que se tuvo un bajo consumo de recursos materiales o de otros elementos que puedan llegar a perjudicar al planeta.

2.4. Valoración social

En el ámbito social, el presente TT tiene una fuerte valoración ya que determinó de que sí existe contenido xenófobo en la red social Twitter, y son tuits que van en contra de los inmigrantes venezolanos en Ecuador, lo que de acuerdo a varias entrevistas como por ejemplo, la realizada a la Psic. Gladys Campoverde¹⁵ que afirma que estos sentimientos de rechazo hacia extranjeros pueden llegar a materializarse con el cometimiento de delitos causados por el odio. Razón por la cual, con los resultados del presente TT se está dando una fuente confiable para que las autoridades de instituciones o fundaciones competentes en esta área, tomen medidas a su criterio que conlleven a generar concientización en la población para erradicar este sentimiento de odio hacia los demás. Se hizo llegar un informe de los resultados del presente TT a algunas autoridades que pueden llegar a tomar acción en sus instituciones a favor de la comunidad (ver Anexo 3).

3. Limitaciones

Como en todo trabajo o proyecto, en el presente TT han existido aspectos que quedaron fuera de la cobertura del mismo, ya que no formaron parte del alcance de los objetivos, pero es importante plasmarlos ya que se brindan los detalles de los problemas que surgieron durante todo el desarrollo del presente TT, así como también, se consideran temas que pueden ser tomados para trabajos futuros, estos son:

3.1. Fiabilidad de los datos recolectados

El conjunto de datos recolectados en Twitter se dio bajo ciertos parámetros como: el rango de la fecha de búsqueda, el idioma, palabras clave y geolocalización, de lo cual, luego de la limpieza del dataset se obtuvieron 9888 tuits para ser procesados y clasificados, pero, de acuerdo a Zannettou [74], en los últimos años ha surgido evidencia de esfuerzos para manipular la opinión pública en la Web, como por ejemplo en eventos políticos importantes, ya sea con cuentas dedicadas o trolls¹⁶, que intervienen en la

¹⁵ <https://drive.google.com/drive/folders/1puJNdQ2vECT-Ry5pVNZp6sJacu5vQ0Iu>

¹⁶ Un 'Troll' es una persona que publica un mensaje deliberadamente provocativo o abusivo con la intención de causar la mayor interrupción y discusión.

difusión de desinformación en las redes sociales, lo que conlleva a cuestionar si la información recolectada proviene de un usuario común, de un troll o de un bot (cuentas automatizadas), si se diera el caso de estos dos últimos, decaería la eficiencia de los resultados de cualquier investigación.

Actualmente, Twitter ha incorporado un filtro de contenidos para evitar los tuits con palabras malsonantes, además, también es capaz de filtrar las notificaciones de cuentas que no nos siguen, que no han cambiado la imagen por defecto de perfil o que no han completado sus datos personales, este tipo de cuentas son presumiblemente trolls, bots o cuentas falsas; así mismo, Twitter ha dado el control a los usuarios sobre quién puede responder a sus tuits, bajo tres tipos de perfiles de conversación: Todos, personas que sigues y solo las personas que mencionas. Según Roth y Pickles [75], Twitter suspende permanentemente millones de cuentas cada mes aquellas que son automatizadas o no deseadas y lo hacen antes que lleguen a los ojos de cualquier resultado de búsqueda; gracias a este trabajo que la red social ya ha venido realizando para identificar y eliminar estas cuentas no deseadas, se puede decir que el total o la mayor parte de los datos recolectados no han sido originados por cuentas falsas.

Aun así, se recomienda para trabajos futuros que durante la recolección de los datos se considere agregar un filtro que descarte a las cuentas que presenten ciertos indicadores como los que comparte el sitio web TrollDor [76]: “serías troll si más del 60% de tus tuits son menciones, si menos de un 80% de tus seguidores escriben en otro idioma diferente al tuyo, si más de un 35% de tus seguidores tienen menos de 30 seguidores y menos de 10 tuits o si más de un 30% de ellos tienen una cuenta abierta hace menos de un mes”.

3.2. Exclusiones y dificultades presentes durante la recolección de los datos

Al inicio del presente TT se plantearon algunas opciones como recolectar los tuits de acuerdo a cada provincia del país, pero esto no fue posible ya que Twitter de forma predeterminada tiene desactivada la ubicación de la cuenta de sus usuarios, restricción que en parte también limitó a la recolección de los tuits entorno a todo el Ecuador, ya que solo alrededor del 10% de los tuits se obtuvieron mediante la geolocalización de los mismos.

Por otra parte, también existieron limitantes para recolectar los tuits ya que Search API de Twitter devuelve tuits solo de hasta hace 7 días, siendo un grave problema para continuar con el proceso de minería de datos y es donde entra en juego la librería en Python TwitterScraper que permite de manera gratuita extraer tuits sin ninguna restricción por su antigüedad u otro factor limitante. Por medio de una lista de

reproducción en YouTube¹⁷ se presenta todo el proceso técnico que se llevó a cabo, incluyendo la ejecución de esta librería.

3.3. Falta de estudios relacionados

Previo a la ejecución del presente TT, empíricamente fueron planteadas las posibles formas de detectar contenido xenófobo en datos textuales, ya que no había estudios en los que ya se haya determinado este sentimiento, la primera alternativa fue realizarlo a través de un experto que ayude en la clasificación de los mismos, pero debido a la gran cantidad (miles) de tuits no resultaba factible que esta tarea sea realizada por una sola persona. Posteriormente, en la ejecución del presente TT se determinó que existe muy poca información bibliográfica en cuanto a la detección de los sentimientos, ya que solo predominan algoritmos y librerías para determinar la polaridad o subjetividad de los mismos, lo que llevó a buscar otras alternativas, como el uso del afinamiento de modelos o fine-tuning, siendo esta la vía exitosa para cumplir con este propósito, luego de una continua indagación en la información bibliográfica se consideró viable afinar un modelo que inicialmente detectaba discursos del odio, para extrapolarlo al contexto de los sentimientos xenófobos, llegando a obtener un nuevo modelo que dio óptimos resultados en la predicción de este sentimiento.

Es importante destacar que los modelos, dataset y el código fuente generado en el todo el proceso técnico del presente TT queda disponible en un repositorio de GitHub¹⁸ para su posterior reproducción o mejoramiento aplicable en trabajos futuros, junto con videos¹⁷ que ayudan a su correcta ejecución.

En general, la falta de recursos como los dataset o el código fuente para reproducir los resultados de otras investigaciones ha llegado ser una gran limitante para los investigadores, ya que se imposibilita mejorar el estudio o continuar con trabajos futuros. Cuando se comparte el conocimiento, los demás podemos ayudar a seguir mejorando.

¹⁷ https://youtube.com/playlist?list=PLiM6EEUFTvE0r5pbn13MNRML_sgFajscs

¹⁸ https://github.com/raulrrv/Deteccion_Xenofobia_TT

8. CONCLUSIONES

De acuerdo al trabajo de titulación realizado, se puede concluir lo siguiente:

- A través de la aplicación de la metodología KDT, se determinó que sí existe contenido xenófobo en la red social Twitter dirigido hacia venezolanos inmigrantes en Ecuador, aunque se encuentra inmerso en menores proporciones, ya que, de los 9888 tuits clasificados solo el 5,76% fue encontrado como xenófobo (570 tuits), sin embargo, esto no significa que el resto de contenido sea amigable, ya que también se halló que el 31,23% de los tuits publicados contienen mensajes ofensivos hacia ellos.
- De acuerdo a la revisión bibliográfica realizada, se pudo determinar que existe muy poca información para detectar sentimientos más complejos como lo es la xenofobia, es decir, los estudios encontrados de análisis de sentimientos en su mayoría determinan solo la polaridad de un texto (positivo, negativo o neutral), por lo cual, mediante el afinamiento de un modelo de clasificación se pueden detectar los sentimientos xenófobos en el conjunto de tuits recolectados, así como también, las herramientas de software, algoritmos, librerías y lenguaje de programación que se utilizaron en el presente TT tienen su importancia para emplearse en trabajos similares o futuros. Es importante mencionar que la metodología de Descubrimiento de Conocimiento en Texto (KDT) permitió realizar exitosamente todo el proceso para la obtención de los resultados esperados.
- Según las pruebas de rendimiento de los modelos de algoritmos de clasificación, se concluye que se obtiene un mejor desempeño cuando las clases del conjunto de entrenamiento han sido equilibradas, dado que se incrementa el número de muestras de las clases minoritarias.
- Comparando los resultados de cada algoritmo de clasificación, se concluye que el algoritmo con mejores resultados de rendimiento durante las predicciones con un 94% de puntuación F1 es el de Máquinas de Soporte Vectorial, así como también cabe mencionar que este algoritmo a diferencia de la Regresión Logística y Naive Bayes, es el que ha llevado un mayor tiempo para la creación del modelo, ya que realiza una búsqueda constante en las clases hasta encontrar el mejor hiperplano que maximice el margen de separación entre estas clases.

9. RECOMENDACIONES

En base al Trabajo de Titulación realizado, se puede dar las siguientes recomendaciones:

- En la etapa de desarrollo de modelos, para mejorar los datos del conjunto de entrenamiento, se recomienda reproducir muestras sintéticas de las clases minoritarias con el objetivo de establecer un equilibrio entre ellas, lo que ofrece una mayor cantidad de muestras que aportan al aprendizaje del modelo y por ende mejoran las predicciones del algoritmo.
- Para evaluar la eficiencia de un modelo, además de dividir el dataset en conjuntos de entrenamiento y prueba; en base a los resultados obtenidos en el presente TT, se recomienda, subdividir el conjunto de datos de entrenamiento para obtener un nuevo conjunto de datos para validación, es decir, este conjunto de validación se emplea para evaluar el modelo creado con el conjunto de entrenamiento, para luego de ajustar y mejorar el modelo se proceda a evaluarlo con el conjunto de prueba que permaneció completamente aislado durante el proceso de entrenamiento y validación del modelo.

Trabajos futuros

- Con fines académicos es factible replicar el proceso de minería de datos realizado en el presente TT en que solo se utilizó código fuente en Python, para que posteriormente se lleve a cabo mediante el uso de programas como RapidMiner, Weka u otros, con el objetivo de comparar los resultados del presente TT que ejecutó los algoritmos de Regresión Logística, Máquinas de Soporte Vectorial y Naive Bayes, frente a los algoritmos que ofrecen las herramientas ya mencionadas. Cabe recordar que para efectuar estos trabajos futuros se ha garantizado la reproducibilidad de esta investigación, con toda la evidencia en GitHub¹⁹ junto con videos²⁰ tutoriales de todo el proceso técnico realizado.
- Implementar una solución de software capaz de automatizar el proceso de clasificación de un conjunto de datos o textos en particular, ya que esto facilitaría demostrar el alcance que llega a tener el Procesamiento de Lenguaje Natural, creando así en los estudiantes interés en conocer cómo funciona este campo de la

¹⁹ https://github.com/raulrry/Deteccion_Xenofobia_TT

²⁰ https://youtube.com/playlist?list=PLiM6EEUFTvE0r5pbn13MNRML_sgFajscs

Inteligencia Artificial. Y esta implementación del software se puede llevar a cabo gracias a que se entrenó un modelo con el algoritmo de mayor rendimiento (SVM) que permite reconocer textos con contenido xenófobo, dicho modelo queda disponible para su utilización (ver [Repositorio](#)²¹).

- En base al trabajo ya realizado en el presente TT, se puede aplicar otros algoritmos para intentar mejorar los resultados, como el algoritmo BERT de Google, que analiza y comprende el contexto y la temática de toda la frase a procesar. Además de que se generan nuevos resultados para ser comparados con los actuales, se impulsa a la investigación práctica en la que se permite al estudiante construir nuevo conocimiento en base a los resultados del presente TT ya propuestos.
- Detectar qué usuarios tienen mayor recurrencia de difundir los mensajes xenófobos u ofensivos, con la finalidad de reportar dichas cuentas o tomar otras medidas, esto se lograría realizar al considerar la característica USERNAME o USER_ID contabilizando la frecuencia con la que dicho usuario publica este tipo de contenido. De esta manera también se incentiva en el ámbito académico a que usando hábilmente las características de un mismo dataset es posible generar mayor conocimiento.

²¹ http://github.com/raulrrv/Deteccion_Xenofobia_TT/blob/master/modelo/modelo_svm_final.pkl

10. BIBLIOGRAFÍA

- [1] M. B. Valdez-Apolo, "El discurso del odio hacia migrantes y refugiados a través del tono y los marcos de los mensajes en Twitter," vol. 6, pp. 361–384, 2019.
- [2] W. Swing, Lacy, *Organización Internacional para las Migraciones*. 2017.
- [3] B. Kitchenham and S. Charters, "Guidelines for performing Systematic Literature Reviews in Software Engineering," 2007.
- [4] T. Davidson, D. Warmesley, M. Macy, and I. Weber, "Automated Hate Speech Detection and the Problem of Offensive Language," in *Proceedings of the 11th International AAAI Conference on Web and Social Media*, 2017, pp. 512–515.
- [5] E. Tanya and P. Mancilla, "Análisis de la Red social Twitter para la identificación de patrones que generan oportunidades de negocio en la ciudad de Guayaquil utilizando el entorno de trabajo Jupyter Notebook y el Lenguaje de Programación Python.," p. 83, 2019.
- [6] H. Watanabe, M. Bouazizi, and T. Ohtsuki, "Hate Speech on Twitter: A Pragmatic Approach to Collect Hateful and Offensive Expressions and Perform Hate Speech Detection," *IEEE Access*, vol. 6, no. c, pp. 13825–13835, 2018.
- [7] R. Sebastian, "El peligro de la xenofobia," no. March, 2019.
- [8] M. Artetxe, G. Labaka Intxauspe, and E. Agirre Bengoa, "Unsupervised Neural Machine Translation, a new paradigm solely based on monolingual text," *Proces. del Leng. Nat.*, no. 63, pp. 151–154, 2019.
- [9] A. Fernández, S. García, F. Herrera, and N. V. Chawla, "SMOTE for Learning from Imbalanced Data: Progress and Challenges, Marking the 15-year Anniversary," *J. Artif. Intell. Res.*, vol. 61, pp. 863–905, 2018.
- [10] C. A. G. Lemaitre, F. Nogueira, D. Oliveira, "SMOTE," 2017. [Online]. Available: https://imbalanced-learn.readthedocs.io/en/stable/generated/imblearn.over_sampling.SMOTE.html#r001eabbe5dd7-1. [Accessed: 27-Jul-2020].
- [11] N. Griffiths, "How To Fine-Tune Your Neural Network For Your Data: Image Classification," 2019. [Online]. Available: <https://towardsdatascience.com/how-to-fine-tune-your-neural-network-for-your-data-image-classification-d0f01c92300b>. [Accessed: 03-Sep-2020].
- [12] E. S. Tellez, S. Miranda-Jiménez, M. Graff, D. Moctezuma, O. S. Siordia, and E. A. Villaseñor, "A case study of Spanish text transformations for twitter sentiment analysis," *Expert Syst. Appl.*, vol. 81, pp. 457–471, 2017.
- [13] J. Camilo, G. Mejía, F. Alberto, and V. Agudelo, "descubrimiento de conocimiento

- (KDD) en bases de datos operativas o transaccionales,” pp. 56–60, 2017.
- [14] S. A. Phand and J. A. Phand, “Twitter sentiment classification using stanford NLP,” *Proc. - 1st Int. Conf. Intell. Syst. Inf. Manag. ICISIM 2017*, vol. 2017-Janua, pp. 1–5, 2017.
- [15] L. Piñón Ferrer, “Minería de datos aplicada a Twitter y análisis de sentimientos mediante algoritmos de inteligencia artificial,” 2018.
- [16] S. A. Phand and V. A. Chakkarwar, “Enhanced Sentiment Classification Using GEO Location Tweets,” *2018 Second Int. Conf. Inven. Commun. Comput. Technol.*, no. Iccict, pp. 881–886, 2018.
- [17] Apollo, “Sitio web de Spyder,” 2019. [Online]. Available: <https://www.spyder-ide.org/>. [Accessed: 09-Jun-2020].
- [18] E. Bisong, *Building Machine Learning and Deep Learning Models on Google Cloud Platform*. 2019.
- [19] R. Kenneth, “Twitter-Scraper,” 2020. [Online]. Available: <https://pypi.org/project/twitter-scraper/>. [Accessed: 09-Jun-2020].
- [20] Pandas, “Biblioteca de análisis de datos de Python - pandas: Biblioteca de análisis de datos de Python,” 2018. [Online]. Available: <https://pandas.pydata.org/>. [Accessed: 27-Jul-2020].
- [21] E. Loper and K. Ewan, “Kit de herramientas de lenguaje natural - documentación NLTK 3.5,” 2009. [Online]. Available: <https://www.nltk.org/>. [Accessed: 27-Jul-2020].
- [22] G. Varoquaux, L. Buitinck, G. Louppe, O. Grisel, F. Pedregosa, and A. Mueller, “Scikit-learn,” *GetMobile Mob. Comput. Commun.*, vol. 19, no. 1, pp. 29–33, 2015.
- [23] M. L. Schmid, “Characterising REGEX languages by regular languages equipped with factor-referencing,” *Inf. Comput.*, vol. 249, no. January, pp. 1–17, 2016.
- [24] C. Schnober, “Biblioteca Joblib Python,” 2019. [Online]. Available: <https://www.admin-magazine.com/HPC/Articles/Parallel-Python-with-Joblib>. [Accessed: 27-Jul-2020].
- [25] Matplotlib, “Matplotlib: Python plotting - documentación de Matplotlib 3.1.1,” 2020. [Online]. Available: <https://matplotlib.org/>. [Accessed: 27-Jul-2020].
- [26] S. Han, “Googletrans: Free and Unlimited Google translate API for Python,” 2018. [Online]. Available: <https://py-googletrans.readthedocs.io/en/latest/>. [Accessed: 27-Jul-2020].
- [27] X. Deng, Q. Liu, Y. Deng, and S. Mahadevan, “An improved method to construct basic probability assignment based on the confusion matrix for classification

- problem,” *Inf. Sci. (Ny)*, vol. 340–341, pp. 250–261, 2016.
- [28] A. Luque, A. Carrasco, A. Martín, and A. de las Heras, “The impact of class imbalance in classification performance metrics based on the binary confusion matrix,” *Pattern Recognit.*, vol. 91, pp. 216–231, 2019.
- [29] A. S. Al Shammari, “Real-time Twitter Sentiment Analysis using 3-way classifier,” *21st Saudi Comput. Soc. Natl. Comput. Conf. NCC 2018*, pp. 1–3, 2018.
- [30] D. Mahajan and D. Kumar Chaudhary, “Sentiment Analysis Using Rnn and Google Translator,” *Proc. 8th Int. Conf. Conflu. 2018 Cloud Comput. Data Sci. Eng. Conflu. 2018*, pp. 798–802, 2018.
- [31] Y. Al-Amrani, M. Lazaar, and K. E. Elkadiri, “Sentiment analysis using supervised classification algorithms,” in *ACM International Conference Proceeding Series*, 2017, vol. Part F1294.
- [32] J. A. Rimassa, “El análisis de opiniones en la predicción política basados en Twitter. Un nuevo enfoque.,” p. 102, 2019.
- [33] B. Herrera Flores, “Polaridad de las opiniones sobre un personaje público en el Ecuador,” vol. V, no. 2, pp. 27–32, 2018.
- [34] W. Elmenreich, J. A. T. Machado, and I. J. Rudas, *Intelligent systems at the service of mankind*, vol. 1, no. January. 2016.
- [35] M. C. Justicia de la Torre, *Nuevas Técnicas De Minería De Textos: Aplicaciones*. 2017.
- [36] D. Rubio Cortés, “Herramienta para el análisis de opiniones y sentimientos sobre Twitter,” 2017.
- [37] J. A. López-Palma and M. Estévez-Crespo, “MOAS-Les, herramienta para el análisis de sentimientos de textos en idioma español,” pp. 1–20, 2016.
- [38] S. V. Luis Yayir, “Evaluación de Algoritmos de Clasificación para el Minado de Opinión en Twitter,” *Rev. la Univ. Señor Sipán*, 2019.
- [39] P. E. Rom and M. G. Armentano, “Herramienta integral de análisis de sentimientos en redes sociales,” 2018.
- [40] J. N. Briones, “Análisis de sentimientos en sistemas de ticketing IT,” 2019.
- [41] O. Hidalgo, R. Jaimes, E. Gomez, and S. Lujan-Mora, “Sentiment analysis applied to the popularity level of the ecuadorian political leader rafael correa,” *Proc. - 2017 Int. Conf. Inf. Syst. Comput. Sci. INCISCOS 2017*, vol. 2017-Novem, pp. 340–346, 2018.
- [42] G. A. Ruz, P. A. Henríquez, and A. Mascareño, “Sentiment analysis of Twitter data during critical events through Bayesian networks classifiers,” *Futur. Gener.*

- Comput. Syst.*, vol. 106, pp. 92–104, 2020.
- [43] H. Rehioui and A. Idrissi, “New clustering algorithms for twitter sentiment analysis,” *IEEE Syst. J.*, vol. 14, no. 1, pp. 530–537, 2020.
 - [44] A. E. Vélez Bravo, “Aplicativo para detectar conductas violentas en Twitter, a través de análisis de sentimientos,” 2020.
 - [45] Y. Gao and S. Wang, “Application & Comparison of several sentiment analysis platforms with open source review dataset,” *ACM Int. Conf. Proceeding Ser.*, no. 2011, 2019.
 - [46] S. A. López and J. J. Cuadrado-Gallego, “Supervised learning methods application to sentiment analysis,” *ACM Int. Conf. Proceeding Ser.*, no. 3, 2019.
 - [47] Q. Li, Q. Zhang, and L. Si, “TweetSenti: Target-dependent tweet sentiment analysis,” *Web Conf. 2019 - Proc. World Wide Web Conf. WWW 2019*, pp. 3569–3573, 2019.
 - [48] S. Alashri, S. Alzahrani, M. Alhoshan, I. Alkhanen, S. Alghunaim, and M. Alhassoun, “Lexi-augmenter: Lexicon-based model for tweets sentiment analysis,” *Proc. - 22nd IEEE Int. Conf. Comput. Sci. Eng. 17th IEEE Int. Conf. Embed. Ubiquitous Comput. CSE/EUC 2019*, pp. 7–10, 2019.
 - [49] R. N. Montufar Mercado, “Automatic Cyberbullying detection in Spanish-Language Social Networks using Sentiment Analysis Techniques,” 2019.
 - [50] L. Talamé, A. Cardoso, and M. Amor, “Comparación de herramientas de procesamiento de textos en español extraídos de una red social para Python,” pp. 53–67.
 - [51] A. Cardoso, L. Talame, M. Amor, and C. Neil, “Minería de Opiniones : Análisis de Sentimientos en una Red Social,” 2019.
 - [52] M. Ruiz, “Análisis de Sentimientos a través de Twitter,” 2019.
 - [53] S. A. El Rahman, F. A. Alotaibi, and W. A. Alshehri, “Sentiment Analysis of Twitter Data,” in *2019 International Conference on Computer and Information Sciences, ICCIS 2019*, 2019.
 - [54] M. I. Sajib, S. Mahmud Shargo, and M. A. Hossain, “Comparison of the efficiency of machine learning algorithms on twitter sentiment analysis of pathao,” *2019 22nd Int. Conf. Comput. Inf. Technol. ICCIT 2019*, pp. 1–6, 2019.
 - [55] A. Trujillo and M. Orellana, “Evaluación de técnicas de procesamiento de lenguaje natural para textos cortos en lenguaje español,” 2018.
 - [56] B. Lin, F. Zampetti, G. Bavota, M. Di Penta, M. Lanza, and R. Oliveto, “Sentiment analysis for software engineering: How Far Can We Go?,” in *Proceedings of the*

- 40th International Conference on Software Engineering, 2018, pp. 94–104.
- [57] T. Chen, R. Xu, Y. He, and X. Wang, “Improving sentiment analysis via sentence type classification using BiLSTM-CRF and CNN,” *Expert Syst. Appl.*, vol. 72, pp. 221–230, 2017.
- [58] I. El Alaoui, Y. Gahi, and R. Messoussi, “Big data quality metrics for sentiment analysis approaches,” *ACM Int. Conf. Proceeding Ser.*, pp. 36–43, 2019.
- [59] P. D. Leonardo, “Análisis de sentimientos. Aplicación sobre textos en redes sociales,” 2019.
- [60] S. Saini, R. Punhani, R. Bathla, and V. K. Shukla, “Sentiment Analysis on Twitter Data using R,” *2019 Int. Conf. Autom. Comput. Technol. Manag. ICACTM 2019*, pp. 68–72, 2019.
- [61] V. Vyas and V. Uma, “An Extensive study of Sentiment Analysis tools and Binary Classification of tweets using Rapid Miner,” *Procedia Comput. Sci.*, vol. 125, pp. 329–335, 2018.
- [62] R. Borja-Robalino, A. Monleón-Getino, and J. Rodellar, “Estandarización de métricas de rendimiento para clasificadores Machine y Deep Learning,” no. June, 2020.
- [63] J. Calloni *et al.*, “Modelo para Analizar Mensajes y Detectar Actitudes Peligrosas a través de Análisis de Sentimientos con Algoritmos de Aprendizajes,” *XIX Work. Investig. en Ciencias la Comput.*, pp. 100–104, 2017.
- [64] K. Sailunaz and R. Alhajj, “Emotion and sentiment analysis from Twitter text,” *J. Comput. Sci.*, vol. 36, p. 101003, 2019.
- [65] E. W. Pamungkas and D. G. P. Putri, “Word sense disambiguation for lexicon-based sentiment analysis,” *ACM Int. Conf. Proceeding Ser.*, vol. Part F1283, pp. 442–446, 2017.
- [66] R. Romero, “Entrevista a Dr. Paul Palacios - Ing Celia Jara Galdeman,” *Google Drive*, 2020. [Online]. Available: <https://drive.google.com/file/d/1gNqSMraM3y-aaevO4w7Cbps1MeIjdnKW/view>. [Accessed: 01-Sep-2020].
- [67] Y. Castán, “Metodo Cientifico y Sus Etapas,” *Castán, Yolanda. Inst. Aragon. Ciencias La Salud*, vol. 2, pp. 1–6, 2006.
- [68] C. E. Montes, *Metodología de investigación tecnológica*. .
- [69] M. Petticrew and H. Roberts, *Systematic Reviews in the Social Sciences*. 2006.
- [70] M. del Interior, “Migración – Ministerio de Gobierno,” *Cifras entras y salidas migración*, 2019. [Online]. Available: <https://www.ministeriodegobierno.gob.ec/migracion/>. [Accessed: 18-Jun-2020].

- [71] WELCOMEAI, “Crowdflower,” 2019. [Online]. Available: <https://www.welcome.ai/crowdflower>. [Accessed: 16-Aug-2020].
- [72] O. M. Cumbicus-Pineda, P. F. Ordoñez-Ordoñez, L. A. Neyra-Romero, and R. Figueroa-Diaz, “Automatic categorization of tweets on the political electoral theme using supervised classification algorithms,” in *Communications in Computer and Information Science*, 2019, vol. 895, pp. 671–682.
- [73] G. Campoverde and R. Romero, “Entrevista a Psicóloga,” *Google Drive*, 2020. [Online]. Available: <https://drive.google.com/drive/folders/1puJNdQ2vECT-Ry5pVNZp6sJacu5vQOlu>. [Accessed: 14-Aug-2020].
- [74] S. Zannettou, M. Sirivianos, T. Caulfield, G. Stringhini, E. De Cristofaro, and J. Blackburn, “Disinformation warfare: Understanding state-sponsored trolls on twitter and their influence on the web,” in *The Web Conference 2019 - Companion of the World Wide Web Conference, WWW 2019*, 2019, pp. 218–226.
- [75] Y. Roth and N. Pickles, “¿Bot o no? Los hechos sobre la manipulación de la plataforma en Twitter,” 2020. [Online]. Available: https://blog.twitter.com/es_la/topics/company/2020/Bot-o-no-Los-hechos-sobre-la-manipulacion-de-la-plataforma-en-Twitter.html. [Accessed: 11-Jan-2021].
- [76] “Trolldor, the global blacklist of twitter trolls.” [Online]. Available: <https://www.trolldor.com/>. [Accessed: 11-Jan-2021].
- [77] C. Mart, “Análisis de Sentimientos en Twitter : El bueno , el malo y el > :(,” 2016.
- [78] D. Yang, A. N. Zhang, and W. Yan, “Performing literature review using text mining, Part I: Retrieving technology infrastructure using Google Scholar and APIs,” *Proc. - 2017 IEEE Int. Conf. Big Data, Big Data 2017*, vol. 2018-Janua, pp. 3290–3296, 2017.
- [79] J. Cardenas, “Odd ratio: qué es y cómo se interpreta,” 2016. [Online]. Available: <http://networkianos.com/odd-ratio-que-es-como-se-interpreta/>. [Accessed: 03-Sep-2020].
- [80] W. J. Wilbur and K. Sirotkin, “The automatic identification of stop words,” *J. Inf. Sci.*, vol. 18, no. 1, pp. 45–55, 1992.

11. ANEXOS

Anexo 1

A continuación, se presenta la TABLA XXX, en la que se plasman todos los lenguajes de programación, algoritmos y herramientas de software que han sido utilizados en los diferentes estudios seleccionados en la revisión bibliográfica del presente TT, entorno al análisis de sentimientos en Twitter.

TABLA XXX
 LENGUAJES DE PROGRAMACIÓN, ALGORITMOS Y HERRAMIENTAS DE SOFTWARE UTILIZADOS EN LOS TRABAJOS
 RELACIONADOS

Lenguajes de programación	Estudios donde fueron utilizados	Lenguaje de programación con mejores resultados (según los autores de cada estudio)	
R	[15] [60]		
Python	[36][40] [63]	[36][40] [63]	
Algoritmos	Estudios donde fueron utilizados	Algoritmos con mejores resultados (según los autores de cada estudio)	Observaciones
Clasificación supervisada			
Super Vector Machine (SVM)	[31] [38] [15] [32] [40] [63] [54] [14] [61] [59]	[38] [15] [14] [61] [59]	
Naive Bayes	[31] [32] [5] [38] [15] [40] [54] [14]	[5] [40]	

	[61] [59]		
Decision Tree	[15] [40] [61]		
Random Forest	[15] [32] [59]		
Neural Network	[40] [59]		
Logistic Regression	[31] [40] [54]	[31]	
PART	[31]		
Máxima Entropía	[14]		
No supervisado			
RAKE (Rapid Automatic Keyword Extractor)	[15]		Extraer y analizar keywords
Clustering (Agrupamiento)			
K-means	[15] [63]		
K.medoids	[15]		
DBSCAN	[15]		
AGNES	[15]		
Herramientas de software	Estudios donde fueron utilizados	Herramientas con mejores resultados (según los autores de cada estudio)	Observaciones
Bibliotecas			Utilidad/Clasificación
Stanford CoreNLP	[41]		Positivo, negativo o

			neutral
Apache OpenNLP	[36]		Clasificación condicional
Text-processing	[36]		
LingPipe	[39]		
Natural Language Toolkit (NLTK)	[31][36] [44] [50]	[36] [44] [50]	Kit de herramientas para PLN
Pandas	[44]	[44]	Manejo de archivos
Word2Vec	[40]		Incorpora métodos de aprendizaje
Matplotlib	[40] [44]	[40] [44]	Genera gráficas
JobLib	[39]	[39]	Exportar e importar archivos
Scikit-Learn	[40] [63] [54] [61] [59] [31] [40][42] [44]	[44] [54] [61] [59]	Kit de herramientas para PLN
Imbalanced-Learn	[42]	[42]	SMOTE
GoogleTrans	[57]	[57]	Machine Translation
Extracción de datos			Observaciones
API REST de Twitter	[36]		Permite el acceso limitado al core de los datos de Twitter

API de Streaming de Twitter	[36]		Solo obtiene los tuits que se publican en tiempo real
Search API de Twitter	[33]		Devuelve tweet de hasta 7 días
Twitter4J	[36]	[36]	
Udpipe en R	[15]		Tokenizar
Plyr en R	[15]		Separa las palabras de los tuits
TwitterScraper	[39]	[39]	
Syuzhet en R	[15]		Diccionario preentendido por Nebraska Literary Lab
RTextTools en R	[15]		
e1071 en R	[15]		
LINQ to Twitter	[41]		Recolección de información
Limpieza de datos			Característica
JMP de SAS	[33]		Limpieza de datos Eliminación de links Tuits vacíos y duplicados

RegEx	[40] [49]	[40] [49]	
Visualizar los datos			
Qlik Sense	[39]		
Análisis de sentimientos			Característica
Sentimient140	[36] [39]		Polaridad: Positivo, negativo o neutral
Google Cloud Natural Language API	[36]		Polaridad: Positivo, negativo o neutral
Microsoft Azure Text Analytics API	[36]		Polaridad: Positivo, negativo o neutral
TheySay PreCeive REST API	[36]		Detección de emociones en imágenes
IBM Watson Natural Language Understanding	[36]		Procesamiento de lenguaje natural
MonkeyLearn	[36]		Procesamiento de lenguaje natural
AFINN: Sentiment / Sentimental / SentimentalJ	[36]		Diccionario de palabras
MOAS-Les	[37]		Polaridad: Positivo, negativo o neutral
25Trends	[39]		

Tweet-mood	[39]		Mide el Ranking de Tuits
Mr. Tuit	[39]		Polaridad: Positivo, negativo o neutral
Software de minería de datos/estadística			
SAS Enterprise Miner	[33]		
RapidMiner	[61]		
SPSS	[32]		
Spyder IDE	[50]	[50]	Entorno de Desarrollo para Python
Google Colab	[44]	[44]	Entorno de Desarrollo Python en la Nube
Metodología			
SEMMA	[33]		Minería de datos
Knowledge Discovery in Texts (KDT)	[34] [35]		Minería de textos

Anexo 2

Entrevistas realizadas con el propósito de sustentar y justificar la realización del presente TT, tanto a nivel social como académico. Como apoyo de la información captada en las entrevistas, se adjunta las grabaciones de las mismas, en el siguiente enlace: <https://drive.google.com/open?id=1qNqSMraM3y-aaevO4w7Cbps1MeIjJdNkW>. A continuación, se redacta fielmente las respuestas vertidas por sus autores.

Entrevista 1

Cargo: Especialista de la Unidad de Bienestar Universitario en el Área de Psicología de la UNL

Nombre: Dr. Paúl Palacios Sotomayor

Fecha: 03/03/2020

Descripción:

1. ¿Considera a la xenofobia como un problema social?

Yo considero que la xenofobia es un problema muy grave, en virtud de que la gente por diferentes patrones culturales, genera a través de ese comportamiento xenofóbico animadversión, segregación e inclusive violencia contra determinadas personas por ser de alguna otra religión, de otro pensamiento político, filosófico e inclusive de nacionalidad.

2. ¿Qué opinión tiene usted acerca de la xenofobia hacia los inmigrantes venezolanos en Ecuador?

Bueno es un hecho sumamente grave, la mayor parte de la gente ecuatoriana ha creado un factor psicológico de animadversión hacia los venezolanos por situaciones de diferente índole, especialmente por los que se dan por medios de comunicación, que no hay una información adecuada, muchos de los venezolanos yo diría la mayor parte son gente honesta, gente buena, pero hay quién que a través de campañas publicitarias especialmente por internet, se ha generado factores, haciendo creer que son personas malas, que son delincuentes, que no trabajan y eso genera la xenofobia, lleva a que se los excluya de la educación, de la salud, de los derechos fundamentales que tiene un ser humano.

3. ¿Considera que las redes sociales en el Ecuador influyen en la propagación de mensajes xenófobos?

Yo creo que sí, las redes sociales son las que generan... yo diría la mayor parte de la xenofobia, porque existe mucha información que no es real, que no es verídica y, por lo

tanto, como el mundo ahora pasa conectado con las redes sociales, esto se convierte en un patrón cultural, que hace que la xenofobia hacia ellos sea muy violenta e inclusive se ha llegado a agredirlos de una manera yo diría inhumana.

4. Realizar un estudio en la red social Twitter para conocer la existencia de mensajes xenófobos hacia los migrantes venezolanos ¿le aportaría de alguna manera?

Yo creo que sí, sería bueno estudiar ese comportamiento a través de Twitter y de las diferentes redes sociales para poder trazar una propuesta que permita que la gente cambie de actitud, porque es un problema de actitud, esa actitud de xenofobia genera muchos problemas, no solamente a nosotros sino fundamentalmente a ellos que necesitan vivir de forma digna, no es correcto que muchos de ellos por la xenofobia tengan que estar sin empleo, sin educación, sin trabajo y en condiciones sumamente precarias, tirados en las calles, niños abandonados; entonces yo creo que se puede hacer bastante a través de Twitter para que la gente cambie de actitud y romper esa xenofobia que hasta ahora es muy violenta.

Entrevista 2

Cargo: Gestora de la Carrera de Trabajo Social de la UNL

Nombre: Ing. Celia Jara Galdeman

Fecha: 03/03/2020

Descripción

1. ¿Considera a la xenofobia como un problema social?

Sí, históricamente la xenofobia ha generado muchos conflictos entre países, entre personas, incluso ha llegado al extremo básicamente de generar hasta la muerte, entonces sí es considerado un problema social.

2. ¿Qué opinión tiene usted acerca de la xenofobia hacia los inmigrantes venezolanos en Ecuador?

Es un sentimiento, una expresión, una posición que de alguna manera denota racismo, denota la no aceptación de otras personas que tienen nacionalidades diferentes a las nuestras o incluso en nuestro medio, personas que vienen de otros lugares o sectores, no es una buena posición porque esto nos genera de alguna manera vulneración de derechos y esa vulneración de derechos afecta a las personas, por ejemplo, el no darle un trabajo, no acceder a los servicios, por ejemplo, como salud, como educación, por el hecho de no ser ciudadanos de cierto sector, de cierta ciudad.

3. ¿Considera que las redes sociales en el Ecuador influyen en la propagación de mensajes xenófobos?

Por supuesto, las redes sociales son medios de difusión sean de buenos o de malos mensajes, en este caso si alguien emite un mensaje con estas características de alguna manera está propiciando, motivando a que otros también lo hagan y ahí se puede generar un conflicto.

4. Realizar un estudio en la red social Twitter para conocer la existencia de mensajes xenófobos hacia los migrantes venezolanos ¿le aportaría de alguna manera?

Por supuesto, realmente esto sería una información muy importante, especialmente para las universidades, una fuente de información para poder proponer alternativas de solución, de hecho, conoceríamos en este caso el origen de las personas, de cuáles son las expresiones y sobre eso, actuar con las propuestas.

El respaldo formal de las entrevistas realizadas se especifica en la siguiente página adjunta.



UNIVERSIDAD NACIONAL DE LOJA

Facultad de Energía, Industrias y Recursos Naturales no Renovables

Carrera de Ingeniería en Sistemas

Entrevista realizada por: Raúl Ramiro Romero Vega

Nombre	Institución/Empresa	Firma
Paul Balsoro S.	U.V. - L (U.R.V)	
CELIA SANDO GARCÍA	U.N.L (Trabajo Social)	

Anexo 3

Informe dirigido a Psic. Gladys Campoverde

Macará, 03 de septiembre de 2020

Psic. Gladys Campoverde

Coordinadora del Departamento de Consejería Estudiantil de la Unidad Educativa Fiscomisional Marista de Macará

De mis consideraciones.

Reciba un cordial saludo y a la vez deseándole toda clase de éxitos en las funciones a su cargo.

La presente tiene la finalidad de poner a su disposición y a la institución a la cual usted representa, los resultados de un estudio¹ que realicé en la carrera de Ingeniería en Sistemas de la Universidad Nacional de Loja, titulado **“Análisis de Sentimientos en Twitter para Descubrir Contenido Xenófobo hacia los Inmigrantes Venezolanos en Ecuador”** en el que se recolectó y analizó un conjunto de 9888 tuits publicados en nuestro país y dirigidos hacia los inmigrantes venezolanos, **en donde se detectó que el 5,76% de tuits contienen sentimientos xenófobos y el 31,23% utilizan un lenguaje ofensivo hacia ellos**, esto denota la existencia de sentimientos de odio hacia este grupo vulnerable como son los inmigrantes, teniendo como posibles consecuencias la afectación a su calidad de vida, a sus derechos como persona e incluso llegar a ser víctimas de delitos causados por este odio. **Por esta razón pongo a vuestra disposición estos resultados para que los consideren como una fuente de información que lleve a tomar acciones en beneficio de su estudiantado y de la comunidad.**

Esperando que el presente informe sea de utilidad para la institución, le expreso mis sentimientos de estima y gratitud.

Atentamente.



Firmado digitalmente por:
**RAUL RAMIRO
ROMERO VEGA**

Raúl Ramiro Romero Vega
**Estudiante de la
Universidad Nacional de Loja**
C.I. 1105234098
Contacto: 0986889241

¹ https://github.com/raulrv/Deteccion_Xenofobia_TT/

RECIBIDO 03/SEP/2020



Gladys Esperanza Campoverde Ludeña
Coord. DECE de la U.E.F.M.M
C.I. 1102441399
Contacto: 0985695115

Informe dirigido a Dr. Paul Palacios Sotomayor

Macará, 03 de septiembre de 2020

Dr. Paul Palacios Sotomayor

Especialista de la Unidad de Bienestar Universitario en el Área de Psicología de la Universidad Nacional de Loja

De mis consideraciones.

Reciba un cordial saludo y a la vez deseándole toda clase de éxitos en las funciones a su cargo.

La presente tiene la finalidad de poner a su disposición y a la institución a la cual usted representa, los resultados de un estudio¹ que realicé en la carrera de Ingeniería en Sistemas de la Universidad Nacional de Loja, titulado **“Análisis de Sentimientos en Twitter para Descubrir Contenido Xenófobo hacia los Inmigrantes Venezolanos en Ecuador”** en el que se recolectó y analizó un conjunto de 9888 tuits publicados en nuestro país y dirigidos hacia los inmigrantes venezolanos, **en donde se detectó que el 5,76% de tuits contienen sentimientos xenófobos y el 31,23% utilizan un lenguaje ofensivo hacia ellos**, esto denota la existencia de sentimientos de odio hacia este grupo vulnerable como son los inmigrantes, teniendo como posibles consecuencias la afectación a su calidad de vida, a sus derechos como persona e incluso llegar a ser víctimas de delitos causados por este odio. **Por esta razón pongo a vuestra disposición estos resultados para que se los considere como una fuente de información que lleve a tomar acciones en beneficio del estudiantado y de la comunidad.**

Esperando que el presente informe sea de utilidad para la institución, le expreso mis sentimientos de estima y gratitud.

Atentamente.



Raúl Ramiro Romero Vega
**Estudiante de la
Universidad Nacional de Loja**
C.I. 1105234098
Contacto: 0986889241

¹ https://github.com/raulrv/Deteccion_Xenofobia_TT/

Informe dirigido a Ing. Celia Jara Galdeman

Macará, 03 de septiembre de 2020

Ing. Celia Jara Galdeman

Gestora de la Carrera de Trabajo Social de la Universidad Nacional de Loja

De mis consideraciones.

Reciba un cordial saludo y a la vez deseándole toda clase de éxitos en las funciones a su cargo.

La presente tiene la finalidad de poner a su disposición y a la institución a la cual usted representa, los resultados de un estudio¹ que realicé en la carrera de Ingeniería en Sistemas de la Universidad Nacional de Loja, titulado **“Análisis de Sentimientos en Twitter para Descubrir Contenido Xenófobo hacia los Inmigrantes Venezolanos en Ecuador”** en el que se recolectó y analizó un conjunto de 9888 tuits publicados en nuestro país y dirigidos hacia los inmigrantes venezolanos, **en donde se detectó que el 5,76% de tuits contienen sentimientos xenófobos y el 31,23% utilizan un lenguaje ofensivo hacia ellos**, esto denota la existencia de sentimientos de odio hacia este grupo vulnerable como son los inmigrantes, teniendo como posibles consecuencias la afectación a su calidad de vida, a sus derechos como persona e incluso llegar a ser víctimas de delitos causados por este odio. **Por esta razón pongo a vuestra disposición estos resultados para que se los considere como una fuente de información que lleve a tomar acciones en beneficio del estudiantado y de la comunidad.**

Esperando que el presente informe sea de utilidad para la institución, le expreso mis sentimientos de estima y gratitud.

Atentamente.



Firmado electrónicamente por:
**RAUL RAMIRO
ROMERO VEGA**

Raúl Ramiro Romero Vega
**Estudiante de la
Universidad Nacional de Loja**
C.I. 1105234098
Contacto: 0986889241

¹ https://github.com/raulrrv/Deteccion_Xenofobia_TT/

Anexo 4

TABLA XXXI
RESULTADOS DE LAS MÉTRICAS POR CLASIFICACIÓN

Clasificador	F1	Recall	Precisión	AUC
Naive Bayes	0.739	0.771	0.71	0.75
SVM	0.721	0.753	0.69	0.73
Logistic Regression	0.730	0.761	0.70	0.74
Tree Decision	0.538	0.909	0.38	0.76
Random Forest	0.666	0.737	0.61	0.70
Perceptron	0.748	0.715	0.78	0.74
MLP	0.857	0.869	0.85	0.84

Anexo 5

TABLA XXXII
MÉTRICAS DE CALIDAD DE BIG DATA

Aspecto	Métrica	Descripción
Fiabilidad	Exactitud	El grado de corrección de datos, fiabilidad y precisión. Obviamente, cuanto más precisos sean los datos, más confiables son las ideas que podemos extraer.
	Integridad	El número de errores en los datos, como registros faltantes o incompletos. Por ejemplo, en contextos de creación de perfiles, la información del usuario se puede utilizar para describir la clase a la que pertenece. Si falta el valor de algunos campos, como la ciudad, la edad o el género, la clase puede no clasificarse correctamente y conducirá a un juicio sesgado.
	Unicidad	Los nuevos registros tienen que ser únicos en comparación con otros conjuntos de datos. Y todo el tiempo, solo hay una entrada de este tipo. Los datos duplicados pondrán un peso extra para el objeto estudiado.
Usabilidad	Transformación	Esto representa tasas de error debido a la transformación de datos. En general, los datos recopilados están en formato sin formato y deben transformarse para seguir un formato más apropiado.
	Conformidad	Big data ya no está representado por datos estructurados sino también semi conjuntos de datos estructurados y no estructurados. Sin embargo, los métodos de análisis requieren un cierto nivel de estructura. Para esto, esta métrica garantiza que los datos sigan un formato estándar.
	Pena de almacenamiento	A veces, los datos deben analizarse en tiempo real. El tiempo dedicado al almacenamiento

		podría afectar la calidad de los resultados.
	Normalización	Asegura que los resultados sean interpretables y comparables entre cada paso en la fase de procesamiento.
	Integridad referencial	Permite garantizar identificadores únicos y válidos para los datos y que cada elemento referencial se represente solo una vez.
Relevancia	Consistencia	La información tiene estar conforme uniforme y no contiene contradicciones La consistencia garantiza la validez interna.
	Credibilidad	Indica cuán significativos y creíbles son los datos. Esta métrica se correlaciona con el contexto estudiado; El significado de los datos debe ser decidido por las necesidades de la aplicación.
	Frescura	Además, se llama puntualidad. Describe el grado en que los datos son actuales para necesidades específicas.

Anexo 6

TABLA XXXIII
COMPARACIÓN DE HERRAMIENTAS DE PLN

Herramienta	Código	Segmentación y Tokenización	Etiquetado POS	Lematización
NLTK	Nativo Python	Sí	Eagles	No
Freeling	API	Sí	Eagles	Sí
Pattern.es	Nativo Python	Sí	Penn TreeBank	Sí
Spacy	Nativo Python	Sí	Penn TreeBank	Sí
Stanford NLP	API	Sí	Eagles	Sí

Anexo 7

TABLA XXXIV

ORACIÓN DE EJEMPLO CON ETIQUETAS EN FORMATO IOB

Palabras:	todavía	el	acto	es	todavía	encantador	aquí	
Etiquetas:	O	B	I	O	O	O	O	O

Anexo 8

TABLA XXXV
COMPARATIVA DE HERRAMIENTAS PARA EL ANÁLISIS DE SENTIMIENTOS

Herramienta	Tipo	Idiomas	Funciones	Límites	Licencia
	Biblioteca	Inglés	Polaridad	-	Open source (GPL)
	Biblioteca	-	Clasificar	-	Open source (Apache)
Sentiment140	Aplicación web con API REST	Inglés Español	Polaridad	1 /segundo 1-4M /día (comercial)	Propietario
	API REST	Inglés + Otros	Polaridad	5000 /mes	Propietario
	API REST	Inglés Español	Polaridad Palabras clave	5000 /mes	Propietario
Text Processing	API REST	Inglés Francés Holandés	Polaridad	1000 /día	NLTK: Open source (Apache)
	API REST	Inglés Español + Otros	Polaridad Emociones	500 /día + 30 /minuto	Propietario
	API REST	Inglés Español + Otros	Polaridad	1000 /día	Propietario
	API REST	Inglés + Otros	Polaridad	1000 /mes	Propietario
AFINN	Listas de palabras (Archivo)	Inglés	Polaridad	-	Open Database License

Anexo 9

text	ext_htm	links	hashtags	has_m
@Corruptos_Fuera un abrazo a los hermanos venezolanos desde ecuador feliz navidad	<p class []	[]		FAL!
Hola chamo como estas? , Sr. Cuanto tiempo tiene fuera del Ecuador?. 1 año! Y porque ese acento??. Es que tu (cont) http://tl.gd/7mgeu9	<p class []	[]		FAL!
@TrapieLlo @ChavezCandanga Chamo el no gobierna el país, el gobierna fuera de Venezuela. Ejm. Bolivia, Argentina, Ecuador etc	<p class []	[]		FAL!
La honrilla llegó al combinado venezolano en ecuador que bien pero insisto fuera Fariás	<p class []	[]		FAL!
@marisaroman30 chamaaaa stoy viendo la mujer perfecta aqui en ecuador soy venezolano y actuas increible fuera el (cont) http://tl.gd/71cq1v	<p class []	[]		FAL!
26' #Ecuador retoma el control del juego, remate desde fuera de David Quiróz obliga a la volada del portero venezolano #fútbol_ec	<p class []	['Ecuador', 'fútbol_ec']		FAL!
Venezolano: Coño! Los Yankees quedaron fuera con los Rangers, Ah.. y Venezuela le gano a Ecuador en Sub20 Por eso es q #EstamosComoEstamos	<p class []	['EstamosComoEstamos']		FAL!
Pedazo de Pendejo!! RT: @VenezuelaNews: Cegados por el odio opositores venezolanos aseguran que hechos de Ecuador son un "montaje"	<p class []	[]		FAL!
@globovision que vaya a vigilia el ni que fuera peo de nosotros los venezolanos lo que pasa en ecuador,	<p class []	[]		FAL!
Facistas!!! Viva el Ecuador, viva la revolución ciudadana, viva Correa y fuera los golpistas. Ecuador el bravo pueblo venezolano te apoyamos	<p class []	[]		FAL!
El Pueblo Venezolano apoyando a Nuestro Camarada el Pdte. Rafael Correa Vamos Ecuador a Defender a su Gobierno Fuera la Ultraderecha	<p class []	[]		FAL!
• Dale #Correa! Hermanos Venezolanos Ponganse Pilas Y Hagan Como En #Ecuador, Fuera #Chavez! #SiSePuede! •	<p class []	['Correa', 'Ecuador', 'Chavez', 'SiSePue		FAL!
Tan mal nos hizo quedar el gobierno venezolano q quedamos como manipuladores de Ecuador de la OEA y además escondiendo a asesinos	<p class []	[]		FAL!
la opocision venezolana cada dia estan mas locos ha hora y que venezuela gobierna a ecuador y si fuera USA que gobernara a venezuela SI	<p class []	[]		FAL!
Q terrible Chavez ha insunflado odio entre seguidores. No parecen criollos. HC es el antimodelo venezolano /via @Diego_Arria atento #ecuador	<p class []	['ecuador']		FAL!
@Corruptos_Fuera un abrazo a los hermanos venezolanos desde ecuador feliz navidad	<p class []	[]		FAL!
Hola chamo como estas? , Sr. Cuanto tiempo tiene fuera del Ecuador?. 1 año! Y porque ese acento??. Es que tu (cont) http://tl.gd/7mgeu9	<p class []	[]		FAL!
@TrapieLlo @ChavezCandanga Chamo el no gobierna el país, el gobierna fuera de Venezuela. Ejm. Bolivia, Argentina, Ecuador etc	<p class []	[]		FAL!
La honrilla llegó al combinado venezolano en ecuador que bien pero insisto fuera Fariás	<p class []	[]		FAL!
@marisaroman30 chamaaaa stoy viendo la mujer perfecta aqui en ecuador soy venezolano y actuas increible fuera el (cont) http://tl.gd/71cq1v	<p class []	[]		FAL!
26' #Ecuador retoma el control del juego, remate desde fuera de David Quiróz obliga a la volada del portero venezolano #fútbol_ec	<p class []	['Ecuador', 'fútbol_ec']		FAL!
Venezolano: Coño! Los Yankees quedaron fuera con los Rangers, Ah.. y Venezuela le gano a Ecuador en Sub20 Por eso es q #EstamosComoEstamos	<p class []	['EstamosComoEstamos']		FAL!
Pedazo de Pendejo!! RT: @VenezuelaNews: Cegados por el odio opositores venezolanos aseguran que hechos de Ecuador son un "montaje"	<p class []	[]		FAL!
@globovision que vaya a vigilia el ni que fuera peo de nosotros los venezolanos lo que pasa en ecuador,	<p class []	[]		FAL!
Facistas!!! Viva el Ecuador, viva la revolución ciudadana, viva Correa y fuera los golpistas. Ecuador el bravo pueblo venezolano te apoyamos	<p class []	[]		FAL!

Fig. 39 Tuits recolectados, aún sin procesar

Anexo 10

TABLA XXXVI
SENTIMIENTOS ENTORNO A LA XENOFOBIA

Sentimientos relacionados con la xenofobia							
antipatía	desavenencia	furor	rencor	discordia	displicencia	animosidad	agresión
ojeriza	desacuerdo	arrebato	resentimiento	antagonismo	indiferencia	prevención	ataque
desafecto	discrepancia	enajenamiento	queja	inquina	ultraje	repugnancia	acometida
desafección	diferencia	irritación	escozor	tirria	repulsa	contradicción	ira
animadversión	disgusto	furia	resquemor	saña	rechazo	resistencia	cabreo
manía	escisión	violencia	ensañamiento	desprecio	retroceso	renuencia	vesania
repulsión	rompimiento	ímpetu	maldad	subestimación	rebote	repelo	horror
mala voluntad	ruptura	impetuosidad	malicia	menosprecio	repudio	asco	oposición
malquerencia	contraposición	frenesí	perversidad	humillación	despido	náuseas	execración
aborrecimiento	incompatibilidad	rozadura	protervia	desaire	abominación	odio	coraje
desestimación	conflicto	excoriación	satanismo	desdén	desamor	propulsa	enfado
desagrado	lucha	inflamación	envidia	vilipendio	enemistad	repudiación	molestia
hostilidad	rabia	incomodidad	dentera	altanería	disconformidad	contienda	orgullo
rivalidad	hidrofobia	encono	pelusa	altivez	discordancia	disputa	arrogancia
enfrentamiento	enojo	aversión	celos	soberbia	disentimiento	querella	desconsideración
enemiga	cólera	fobia	indignación	engreimiento	riña	pendencia	pelea

Anexo 11

TABLA XXXVII
CATEGORIZACION DE LAS HERRAMIENTAS PARA ANALIZAR TEXTOS

Herramienta	Aplicación	Fuentes web
Lexalytics	Natural Language Processing (NLP), Text Analysis	https://www.lexalytics.com/technology/sentiment
IBM Watson Alchemy API	NLP, Text Analytics, Content Recommendation	https://www.ibm.com/watson/developercloud/alchemy-language.html
Provalis Research Analytics Software	Text analysis,	https://provalisresearch.com/
SAS Text Miner	Content Analysis Text analysis, Ontology, Sentiment Analysis, NLP	https://www.sas.com
Sysomos	Social media monitoring, Text Analysis	https://sysomos.com
Expert system	Semantic Search, NLP, Content Analysis	www.expertsystem.com
Rapid miner	Text mining, Social media analysis, Market Search NLP, Text Analytics,	https://rapidminer.com
Clarabridge	Social media Analysis, Sentiment Analysis	www.clarabridge.com/text-analytics
Luminoso	Text analysis	https://luminoso.com
Bitext	Sentiment Analysis, Concept Extraction, Text Analysis	https://www.bitext.com/
Etuma	Social media monitoring, Sentiment Analysis	https://www.etuma.com/
Synapsify	Social media monitoring, Text mining	www.gosynapsify.com
Medallia	Social media monitoring, Text mining	www.medallia.com
Abzooba	Social media monitoring, Text Analysis	www.abzooba.com/

General Sentiment	Sentiment Analysis, Text mining, Social media analytics	www.generalsentiment.com
Semantria	Text analysis by API and Excel plugin, Sentiment Analysis	https://semantria.readme.io/
VisualText	NLP, Text Analytics Text analysis	www.textanalysis.com
Buzzlogix	Sentiment Analysis, Social Media Monitoring	https://buzzlogix.com
Averbis	Text analytics, Information Discovery	https://averbis.com/en/
AYLIEN	Text analysis, NLP, Concept Extraction	aylien.com

Anexo 12

A continuación, se adjunta el producto final de la Revisión Sistemática de Literatura, presentado como artículo.

Revisión Sistemática de Literatura: Análisis de Sentimientos para el Descubrimiento de Contenido Xenófobo en Twitter

Romero-Vega Raúl Ramiro, Cumbicus-Pineda Oscar M.

Carrera de Ingeniería en Sistemas

Universidad Nacional de Loja, Loja-Ecuador

raul.romero@unl.edu.ec, oscar.cumbicus@unl.edu.ec

Abstract-- The information publicly released on social networks are not always positive ideas or thoughts, as they register an increase in hate speech and the dissemination of racist, xenophobic, or intolerant messages, or that point to others as a threat, giving the possibility of committing hate crimes.

The present Systematic Literature Review (SLR) had the purpose of identifying which programming language, algorithms, tools and software in general are necessary to perform a sentimental analysis that allows the recognition of the existence of xenophobic content in a set of tweets. Since conventional software tools are limited to finding only the polarity or subjectivity of feelings. This SLR was based on the phases of Barbara Kitchenham's methodology, through the approach of four research questions defined the course of the review; obtaining Python as programming language, Logistic Regression, Naïve Bayes and Support Vector Machine as classification algorithms and a set of libraries more suitable for the detection of xenophobic feelings.

Resumen— La información vertida públicamente en las redes sociales no siempre son ideas o pensamientos positivos, ya que registran un incremento del discurso del odio y de difusión de mensajes racistas, xenófobos, de intolerancia, o que señalen a los demás como una amenaza, dando la posibilidad de que se cometan delitos de odio.

La presente Revisión Sistemática de Literatura (RSL) tuvo el propósito de identificar qué lenguaje de programación, algoritmos, herramientas y software en general son necesarios para realizar un análisis de sentimientos que permita reconocer la existencia de contenido xenófobo en un conjunto de tuits. Dado que las herramientas de software convencionales están limitadas a encontrar solo la polaridad o subjetividad de los sentimientos. Esta RSL se basó en las fases de la metodología de Bárbara Kitchenham, mediante el planteamiento de cuatro preguntas de investigación se definió el transcurso de la revisión; obteniendo a Python como lenguaje programación, la Regresión Logística, Naive Bayes y Máquinas de Soporte Vectorial como algoritmos de clasificación y un conjunto de las

librerías más idóneas para la detección de los sentimientos xenófobos.

Keywords- hate speech, sentiment analysis, xenophobia, natural language processing.

I. INTRODUCCIÓN

Actualmente, las personas tienen la libertad de crear y compartir su propio contenido públicamente en las redes sociales, particularmente en la plataforma de microblogging Twitter [74], siendo una red social que se caracteriza por la crítica en masas, críticas que se pueden convertir en discursos del odio²² como la xenofobia, que genera la vulneración de los derechos de las personas, habiendo formas de prevenir estos delitos de odio mediante la detección a tiempo de estos sentimientos xenófobos en la población, siendo esta una tarea difícil de conocer a través de las técnicas tradicionales como las encuestas, debido a los estigmas que existen entorno al racismo y la xenofobia, conocido como sesgo de deseabilidad social.

En la presente RSL, a través de las fases de la metodología de Bárbara Kitchenham se ha podido encontrar estudios o trabajos relacionados que permitieron identificar los insumos necesarios para el análisis de sentimientos en Twitter y el descubrimiento de contenido xenófobo.

El presente estudio se realizó por secciones como: el Alcance, donde se determina el propósito que tiene realizar la presente RSL, a continuación, en la sección de Metodología se definieron las fases a seguir que propone Kitchenham para realizar revisiones de literatura, posteriormente, se realiza el proceso para cada una de las fases propuestas detallando el proceso y las salidas en la sección de Resultados y finalmente, se plantean las Conclusiones obtenidas durante la realización de la presente RSL.

II. ALCANCE

La presente Revisión Sistemática de Literatura tiene como propósito analizar los estudios o trabajos relacionados acerca del análisis de sentimientos en Twitter para descubrir contenido xenófobo en los tuits, para lo que se requiere identificar el

(como raza, religión, orientación sexual, nacionalidad o discapacidad)

²² Discursos del odio: Según Watanabe et al. [6], son discursos que tienen la intención de insultar, ofender o intimidar a una persona debido a algún rasgo

lenguaje de programación, los algoritmos, las herramientas y el software en general necesario para realizar dicho análisis de sentimientos.

III. METODOLOGÍA

La realización de la revisión sistemática de literatura se basa en el proceso de la metodología de Bárbara Kitchenham [3], dicho proceso se resume en tres fases principales: Planificación de la revisión, Realizar la revisión y Revisión de informes.

De acuerdo a Kitchenham [3], algunas tareas de estas fases no son obligatorias, como por ejemplo:

- Puesta en marcha de una revisión, depende de si o no la revisión sistemática que se está haciendo sobre una base comercial.
- Evaluar el protocolo de revisión y la evaluación del informe, son opcionales y dependen de los procedimientos de garantía de calidad decididas por el encargado de la revisión sistemática.

Para el presente trabajo no se ejecutaron todos los pasos propuestos por Kitchenham, justamente porque su metodología es flexible en cuanto a la extensión que el investigador necesite dar a su revisión, como por ejemplo, en la fase de Revisión de Informes, se solicita especificar los mecanismos de difusión, los mismos que depende del alcance que el investigador requiera dar a la presentación y publicación de sus resultados. De acuerdo a esto, en la TABLA XXXVIII, se presentan las fases y tareas que fueron consideradas:

TABLA XXXVIII
PROCESO DE REVISIÓN SISTEMÁTICA DE LITERATURA PROPUESTO

Fases	Tareas
Planificación de la revisión	Identificación de la necesidad de una revisión.
	Especificación de las preguntas de investigación.
	El desarrollo de un protocolo de revisión.
Realizar la revisión	Identificación de la investigación.
	Selección de los estudios primarios.
	Síntesis de los datos.
Revisión de informes	Dar formato al informe principal.

Las fases y tareas anteriormente descritas han sido realizadas para cumplir con el propósito planteado en la sección Alcance.

IV. RESULTADOS

A. Planificación de la revisión

1) Identificación de la necesidad de una revisión

A través de la ejecución de una revisión sistemática de literatura, se permite descubrir el conocimiento que existe entorno a cierto tema de investigación; en este caso fue necesaria para elegir la metodología, el lenguaje de programación, los algoritmos, las herramientas y el software en general más acorde para el análisis de sentimientos en Twitter. Para cumplir correctamente el alcance anteriormente propuesto se ha determinado cuatro preguntas de investigación.

2) Preguntas de investigación

A continuación, en la TABLA XXXIX se presentan las preguntas de investigación que definieron el curso de la revisión bibliográfica, dichas preguntas que se abordaron en este estudio son:

TABLA XXXIX
PREGUNTAS DE INVESTIGACIÓN

Preguntas de investigación	
P1	¿Qué metodología de minería de datos/textos es más factible emplear para el análisis de sentimientos en Twitter?
P2	¿Cuál es el lenguaje de programación, algoritmos, herramientas y el software en general necesario para realizar el análisis de sentimientos en Twitter?
P3	¿Cuáles son las herramientas de software necesarias para la interpretación de los resultados obtenidos?
P4	¿Cómo determinar la existencia de sentimientos que están entorno a la xenofobia?

3) El desarrollo de un protocolo de revisión

a) Diseño del protocolo de búsqueda

(1) Estrategias de búsqueda

Petticrew y Roberts [69], recomiendan criterios para plantear la investigación, mediante el uso de la nemotécnica PICOC (Población, Intervención, Comparación, Resultado y Contexto), se estructuran los cinco componentes para definir la cadena de búsqueda; así como también, para una mejor organización y selección de todos los resultados, se utilizó la herramienta en línea Parsifal²³, la cual ayuda en el contexto de la Ingeniería del Software para realizar revisiones sistemáticas de literatura.

(2) Fuentes bibliográficas

Como fuentes bibliográficas, se ha seleccionado algunas bibliotecas virtuales, como son:

- IEEE Digital Library (<https://ieeexplore.ieee.org/>)
- Science@Direct (<https://www.sciencedirect.com/>)
- ACM Digital Library (<https://dl.acm.org/>)
- Google Scholar (<https://scholar.google.com/>)

Existen contrariedades entorno a la utilización de Google Scholar como una fuente bibliográfica primaria, a razón de que

²³ <https://parsif.al/>

sus resultados no siempre son estudios científicos, sin embargo, de acuerdo a Zhang [75], Google Scholar es uno de los mejores indexadores de contenido de literatura científica y académica, pero, advierte que se debe utilizar con cuidado ya que también incluye sitios web que no realizan un control de calidad de sus trabajos científicos, es decir, usado correctamente es válido considerarlo como una fuente bibliográfica primaria y/o secundaria.

(3) Definir palabras claves para el problema de estudio

Con la definición de los criterios PICOC se obtuvo un conjunto de palabras claves, las mismas que permitieron construir las cadenas de búsquedas, estas son: Algoritmos, Librerías, Metodologías, Métodos, Procesamiento de Lenguaje Natural, Lenguaje de Programación, Análisis de Sentimientos, Software, Técnicas, Herramientas, Discursos del Odio, Tuits, Twitter. Así como también su traducción al inglés: Algorithms, Libraries, Methodologies, Methods, Natural Language Processing, Programming Language, Sentiment Analysis, Software, Techniques, Tools, Hate Speech, Tweets, Twitter.

(4) Cadenas de búsqueda

En la TABLA XL se presentan las cadenas de búsqueda aplicadas tanto en inglés como su traducción al español, se realizaron de acuerdo a cada biblioteca virtual: IEEE Digital Library, Science@Direct, ACM Digital Library y Google Scholar.

(5) Criterios de inclusión

Durante la búsqueda, se consideraron los siguientes criterios de inclusión:

- **Fecha de publicación:** artículos publicados desde el año 2016 hasta el 2020.
- **Idioma:** se consideró artículos en inglés y español.
- **Tipos de estudios:** artículos, revistas, libros y tesis.

(6) Criterios de exclusión

Se descartaron aquellos documentos que no responden a las

preguntas de investigación, así como los que no cumplen con los criterios de inclusión.

B. Realizar la revisión

1) Identificación de la investigación

El objetivo de la presente revisión sistemática de literatura, es dar respuesta a las preguntas de investigación, a través de la búsqueda de estudios primarios que contribuyan con información fiable entorno a los temas de interés.

2) Selección de los estudios primarios

Para realizar la selección de los estudios se ha seguido el siguiente proceso (ver Fig. 40):

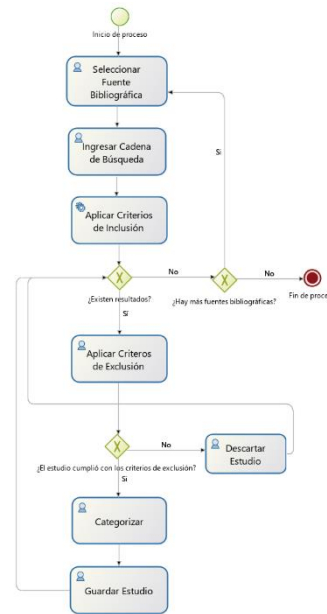


Fig. 40 Proceso de Selección de Estudios

TABLA XL
CADENAS DE BÚSQUEDA

Bibliotecas virtuales	Cadenas de búsqueda
IEEE Digital Library	("hate speech" OR "tweets" OR "twitter") AND ("algorithms" OR "libraries" OR "methodologies" OR "methods" OR "programming language" OR "software" OR "techniques" OR "tools") AND ("natural language processing" OR "sentiment analysis")
Science@Direct	("hate speech" OR "tweets" OR "twitter") AND ("algorithms" OR "libraries" OR "methodologies" OR "methods" OR "programming language" OR "software" OR "techniques" OR "tools") AND ("natural language processing" OR "sentiment analysis")
ACM Digital Library	("hate speech" OR "tweets" OR "twitter") AND ("algorithms" OR "libraries" OR "methodologies" OR "methods" OR "programming language" OR "software" OR "techniques" OR "tools") AND ("natural language processing" OR "sentiment analysis")
Google Scholar	("hate speech" OR "tweets" OR "twitter") + ("algorithms" OR "libraries" OR "methodologies" OR "methods" OR "programming language" OR "software" OR "techniques" OR "tools") + ("natural language processing" OR "sentiment analysis")

En la TABLA XLI se presenta un resumen de los trabajos o estudios relacionados que fueron encontrados junto con el número de estudios seleccionados según la fuente bibliográfica.

Se obtuvieron 43 estudios relacionados, estos se detallan a continuación, en la TABLA XLII.

TABLA XLI
RESUMEN DE ESTUDIOS SELECCIONADOS

Fuente Bibliográfica	Encontrados	Seleccionados
IEEE Digital Library	99	14
Science@Direct	100	6
ACM Digital Library	100	13
Google Scholar	97	10
TOTAL	396	43

TABLA XLII
ESTUDIOS SELECCIONADOS

N°	Estudios seleccionados	Ref.	Términos	Buscador
ES01	Real-time Twitter Sentiment Analysis using 3-way classifier	[29]	R; Sentiment Analysis; Opinion Mining; Polarity; Twitter	IEEE Xplore
ES02	Sentiment Analysis Using RNN And Google Translator	[30]	Tools, Machine Translation	IEEE Xplore
ES03	A case study of Spanish text transformations for twitter sentiment analysis	[12]	Sentiment Analysis, Opinion	ScienceDirect
ES04	Sentiment Analysis Using Supervised Classification Algorithms	[31]	Logistic Regression, Classification, Naive Bayes, Sentiment Analysis	ACM Digital Library
ES05	El análisis de opiniones en la predicción política basados en Twitter. Un nuevo enfoque.	[32]	Twitter, Herramientas, Software, Twitter.	Google Scholar
ES06	Análisis de la Red social Twitter para la identificación de patrones que generan oportunidades de negocio en la ciudad de Guayaquil utilizando el entorno de trabajo Jupyter Notebook y el Lenguaje de Programación Python.	[5]	Análisis de Sentimientos, Twitter, Lenguaje de Programación, Algoritmos.	Google Scholar
ES07	Polaridad de las opiniones sobre un personaje público en el Ecuador	[33]	Análisis De Sentimientos, Procesamiento Del Lenguaje Natural.	ACM Digital Library
ES08	Text Mining for Documents Annotation and Ontology Support	[34]	Methodologies, Natural Language Processing	Google Scholar
ES09	Nuevas Técnicas De Minería De Textos: Aplicaciones	[35]	Metodologías, Procesamiento de Lenguaje Natural, Técnicas.	Google Scholar
ES10	Herramienta para el análisis de opiniones y sentimientos sobre Twitter	[36]	Twitter, Análisis De Sentimientos.	Google Scholar
ES11	MOAS-Les, herramienta para el análisis de sentimientos de textos en idioma español	[37]	Análisis De Sentimientos, Herramientas.	Google Scholar
ES12	Evaluación de Algoritmos de Clasificación para el Minado de Opinión en Twitter	[38]	Algoritmos, Twitter.	ScienceDirect
ES13	Minería de datos aplicada a Twitter y análisis de sentimientos mediante algoritmos de inteligencia artificial	[15]	Twitter, Análisis de Sentimientos, Algoritmos.	Google Scholar
ES14	Herramienta integral de análisis de sentimientos en redes sociales	[39]	Herramientas, Análisis de Sentimientos.	ScienceDirect
ES15	Análisis de sentimientos en sistemas de ticketing IT	[40]	Análisis De Sentimientos, Software.	ACM Digital Library
ES16	Sentiment analysis applied to the popularity level of the ecuadorian political leader Rafael Correa	[41]	Análisis de Sentimientos, Twitter, Procesamiento de Lenguaje Natural.	ScienceDirect

ES17	Sentiment analysis of Twitter data during critical events through Bayesian networks classifiers	[42]	Análisis de Sentimientos, Twitter, Algoritmos.	IEEE Xplore
ES18	New Clustering Algorithms for Twitter Sentiment Analysis	[43]	Algoritmos, Análisis de Sentimientos, Twitter.	IEEE Xplore
ES19	Aplicativo para detectar conductas violentas en Twitter, a través de análisis de sentimientos	[44]	Twitter, Análisis de Sentimientos.	ACM Digital Library
ES20	Application & Comparison of Several Sentiment Analysis Platforms with Open Source Review Dataset	[45]	Software, Análisis de Sentimientos, Algoritmos.	ACM Digital Library
ES21	Supervised learning methods application to sentiment analysis	[46]	Análisis de Sentimientos, Software, Análisis de Sentimientos, Métodos.	ACM Digital Library
ES22	Tuitsenti: Target-dependent tweet sentiment analysis	[47]	Análisis de Sentimientos, Twitter, Algoritmos.	ACM Digital Library
ES23	Lexi-augmenter: Lexicon-based model for tuits sentiment analysis	[48]	Análisis de Sentimientos, Tuits, Métodos.	IEEE Xplore
ES24	Automatic Cyberbullying detection in Spanish-Language Social Networks using Sentiment Analysis Techniques	[49]	Análisis de Sentimientos, Técnicas, Herramientas, Algoritmos.	IEEE Xplore
ES25	Comparación de herramientas de procesamiento de textos en español extraídos de una red social para Python	[50]	Procesamiento de Leguaje Natural, Algoritmos, Lenguaje de Programación.	Google Scholar
ES26	Minería de Opiniones: Análisis de Sentimientos en una Red Social	[51]	Análisis de Sentimientos, Twitter.	ACM Digital Library
ES27	Análisis de Sentimientos a través de Twitter	[52]	Análisis de Sentimientos, Twitter, Algoritmos, Tuits.	ACM Digital Library
ES28	Sentiment Analysis of Twitter Data	[53]	Análisis de Sentimientos, Twitter.	IEEE Xplore
ES29	Comparison of the efficiency of Machine Learning algorithms on Twitter Sentiment Analysis Of Pathao	[54]	Análisis de Sentimientos, Twitter, Algoritmos.	IEEE Xplore
ES30	Enhanced Sentiment Classification Using GEO Location Tuits	[16]	Tuits; Procesamiento de Lenguaje Natural, Análisis de Sentimientos, Twitter.	IEEE Xplore
ES31	Evaluación de técnicas de procesamiento de lenguaje natural para textos cortos en lenguaje español	[55]	Procesamiento de Lenguaje Natural, Técnicas, Análisis de Sentimientos.	Google Scholar
ES32	Sentiment Analysis for Software Engineering: How Far Can We Go?	[56]	Software Engineering, Sentiment Analysis, NLP	IEEE Xplore
ES33	Improving sentiment analysis via sentence type classification using BiLSTM-CRF and CNN	[57]	Natural Language Processing, Sentiment Analysis, Deep Neural Network	ScienceDirect
ES34	Big data quality metrics for sentiment analysis approaches	[58]	Análisis de Sentimientos, Algoritmos.	IEEE Xplore
ES35	Análisis de sentimientos. Aplicación sobre textos en redes sociales	[59]	Análisis de Sentimientos, Twitter.	ACM Digital Library
ES36	Sentiment Analysis on Twitter Data using R	[60]	Análisis de Sentimientos, Twitter, Lenguaje de Programación, Herramientas.	IEEE Xplore
ES37	An Extensive study of Sentiment Analysis tools and Binary Classification of tuits using Rapid Miner	[61]	Text Mining; Sentiment Analysis; Twitter; Rapid Miner	ScienceDirect
ES38	Twitter sentiment classification using stanford NLP	[14]	Opinion, Fetch Twitter Data, Twitter API, Sentiment Analysis	IEEE Xplore
ES39	Estandarización de métricas de rendimiento para clasificadores Machine y Deep Learning	[62]	Clasificador, Métricas de Evaluación, Rendimiento	Google Scholar
ES40	Automated Hate Speech Detection and the Problem of Offensive Language	[4]	Hate Speech, Twitter, Libraries, Algorithm	ACM Digital

				Library
ES41	Modelo para Analizar Mensajes y Detectar Actitudes Peligrosas a través de Análisis de Sentimientos con Algoritmos de Aprendizajes	[63]	Análisis de Sentimientos, Algoritmos.	ACM Digital Library
ES42	Emotion and Sentiment Analysis from Twitter Text	[64]	Análisis de Sentimientos, Twitter, Tweets.	IEEE Xplore
ES43	Word Sense Disambiguation for Lexicon-Based Sentiment Analysis	[65]	Sentiment Analysis, Lexicon-Based, Opinion Mining	ACM Digital Library

3) Síntesis de los datos

Cada estudio fue analizado para identificar su aporte más relevante y así finalmente obtener los nombres en concreto de los software requeridos que contestan a las preguntas de investigación inicialmente planteadas (ver TABLA XXXIX).

a) ¿Qué metodología de minería de datos/textos es más factible emplear para el análisis de sentimientos en Twitter?

De acuerdo a los estudios [29] [30] [12] [31] [32] [5] [33] [35] [34] el análisis de sentimientos en Twitter se puede realizar mediante las siguientes fases:

- Obtención de tuits
- Extracción de características
- Preprocesamiento de los datos
- Aplicación de algoritmos supervisados
 - Training Set
 - Testing Set
- Evaluación
- Representación gráfica

Dichas fases se las pudo contrastar con la metodología para el descubrimiento del conocimiento en texto (utilizada en los estudios [35] [34]), conocida como KDT (Knowledge Discovery in Text) que de acuerdo a Elmenreich [34], consta de las siguientes etapas:

- Comprender el dominio de la aplicación y los objetivos del proceso KDT
- Adquisición o selección de un conjunto de datos objetivo
- Limpieza de datos, preprocesamiento y transformación
- Desarrollo de modelos y construcción de hipótesis
- Elección y ejecución de algoritmos de minería de datos adecuados
- Interpretación y visualización de resultados

Relacionando las etapas de la metodología KDT (Descubrimiento De Conocimiento En Texto) con las fases propuestas por los autores ya mencionados, se consideró factible emplear dicha metodología para el análisis de sentimientos en Twitter. A continuación, en la TABLA XLIII se presenta dicha relación.

TABLA XLIII
RELACIÓN DE LAS FASES PARA EL ANÁLISIS DE SENTIMIENTOS EN TWITTER Y KDT

Fases para el análisis de sentimientos en Twitter	Etapas de la metodología KDT
<ul style="list-style-type: none"> • Obtención de tuits 	<ul style="list-style-type: none"> • Comprender el dominio de la aplicación y los objetivos del proceso KDT • Adquisición o selección de un conjunto de datos objetivo
<ul style="list-style-type: none"> • Extracción de características • Preprocesamiento de los datos 	<ul style="list-style-type: none"> • Limpieza de datos, preprocesamiento y transformación
<ul style="list-style-type: none"> • Aplicación de algoritmos supervisados <ul style="list-style-type: none"> ○ Training Set ○ Testing Set 	<ul style="list-style-type: none"> • Desarrollo de modelos y construcción de hipótesis • Elección y ejecución de algoritmos de minería de datos adecuados
<ul style="list-style-type: none"> • Evaluación • Representación gráfica 	<ul style="list-style-type: none"> • Interpretación y visualización de resultados

Cabe mencionar que, en los estudios encontrados, la mayoría de sus autores no especifican una metodología para el análisis de los textos, esto no significa que no lleven un orden en el proceso para dicho análisis, sino que emplean solo las fases que estrictamente requieran para dar cumplimiento a su propósito de análisis de sentimientos.

Finalmente, se consideró factible utilizar la metodología KDT para el análisis de sentimientos en Twitter.

b) ¿Cuál es el lenguaje de programación, algoritmos, herramientas y el software en general necesario para realizar el análisis de sentimientos en Twitter? y ¿Cuáles son las herramientas de software necesarias para la interpretación de los resultados obtenidos?

De acuerdo a los estudios [34] [35] [36] [15] [37] [38] [39] [40] [41] [42] [43] [44] [45] [46] [47] [48] [49] [50] [51] [52] [16] [53] [54] [55] [58] [59] [60] [61] [14] [62] se seleccionó el lenguaje de programación, algoritmos, herramientas y el software general necesario que, según los autores de dichos trabajos han dado los mejores resultados en cuanto al tratamiento de textos, para la recolección de tuits, el análisis de sentimientos y la representación e interpretación de los resultados. A continuación, en la TABLA XLIV se presentan

dichos software.

TABLA XLIV
 LENGUAJE DE PROGRAMACIÓN, ALGORITMOS Y HERRAMIENTAS DE
 SOFTWARE NECESARIOS PARA LA EJECUCIÓN DE LA METODOLOGÍA KDT

Lenguaje de programación	<ul style="list-style-type: none"> • Python
Algoritmos	<ul style="list-style-type: none"> • Naive Bayes • Support Vector Machines (SVM) • Logistic Regression
Herramientas de software	<ul style="list-style-type: none"> • Spyder IDE • Google Colab
Bibliotecas	<ul style="list-style-type: none"> • Twitter Scraper • Pandas • NLTK • Scikit-Learn • Imbalanced-Learn (SMOTE) • RegEx • JobLib • Matplotlib • GoogleTrans

c) ¿Cómo determinar la existencia de sentimientos que están entorno a la xenofobia?

De los estudios [4] [63] [64] [65] que aportaron a dar respuesta a esta pregunta de investigación, el estudio que más destacó es el de Davidson et al. [4], ya que para detectar los sentimientos han utilizado la técnica de crowdsourcing²⁴ para clasificar los tuits en tres categorías: discursos del odio, lenguaje ofensivo y ninguno, posteriormente, han entrenado un modelo con estos patrones, el mismo que pueden ser utilizado para otras investigaciones, como por ejemplo para la detección de xenofobia ya que este sentimiento también está contemplado como un discurso del odio.

C. Revisión de informes

4) Dar formato al informe principal

Esta tarea hace referencia a la creación del informe con el proceso realizado para la obtención de resultados, es decir, el presente trabajo de RSL es el informe a considerar.

V. CONCLUSIONES

De acuerdo a la RSL realizada se han obtenido las siguientes conclusiones:

- Muchos de los autores de cada trabajo relacionado no mencionan una metodología en concreto para realizar el análisis de sentimientos en Twitter, sino que plantean una serie de pasos para llegar a realizar el mismo fin, mediante una comparación de estos pasos genéricos con los de las metodologías encontradas, se concluyó en

utilizar la metodología KDT para el análisis de sentimientos xenófobos en Twitter.

- Se ha concluido que los algoritmos Regresión Logística, Máquinas de Soporte Vectorial y Naive Bayes son los que mejor desempeño tienen para el análisis de datos textuales y clasificación a través de modelos de aprendizaje supervisado.
- Las librerías como NLTK, Imbalanced-Learn y Scikit-Learn son las que mayormente destacan en los estudios encontrados, ya que NLTK ofrece un amplio kit de herramientas para el procesamiento de lenguaje natural como diccionarios de stopwords, lematización, tokenización, etc., Imbalanced-Learn cuenta con la Técnica de Sobremuestreo de Minorías Sintéticas (SMOTE) y Scikit-Learn proporciona los algoritmos de clasificación necesarios para el proceso de análisis de sentimientos.
- Para detectar la xenofobia en los tuits, se concluyó que se puede realizar a través del afinamiento de un modelo inicialmente creado por Davidson T.²⁵, el cual clasificó un conjunto de tuits mediante crowdsourcing, los mismos que contenían mensajes con discursos del odio y lenguaje ofensivo.

VI. REFERENCIAS

[1] M. B. Valdez-Apolo, "El discurso del odio hacia migrantes y refugiados a través del tono y los marcos de los mensajes en Twitter," vol. 6, pp. 361–384, 2019.

[2] W. Swing, Lacy, *Organización Internacional para las Migraciones*. 2017.

[3] B. Kitchenham and S. Charters, "Guidelines for performing Systematic Literature Reviews in Software Engineering," 2007.

[4] T. Davidson, D. Warmlesley, M. Macy, and I. Weber, "Automated Hate Speech Detection and the Problem of Offensive Language," in *Proceedings of the 11th International AAI Conference on Web and Social Media*, 2017, pp. 512–515.

[5] E. Tanya and P. Mancilla, "Análisis de la Red social Twitter para la identificación de patrones que generan oportunidades de negocio en la ciudad de Guayaquil utilizando el entorno de trabajo Jupyter Notebook y el Lenguaje de Programación Python.," p. 83, 2019.

[6] H. Watanabe, M. Bouazizi, and T. Ohtsuki, "Hate Speech on Twitter: A Pragmatic Approach to Collect Hateful and Offensive Expressions and Perform Hate Speech Detection," *IEEE Access*, vol. 6, no. c, pp. 13825–13835, 2018.

[7] R. Sebastian, "El peligro de la xenofobia," no. March, 2019.

[8] M. Artetxe, G. Labaka Intxauspe, and E. Agirre Bengoa, "Unsupervised Neural Machine Translation, a new paradigm solely based on monolingual text," *Proces. del Leng. Nat.*, no. 63, pp. 151–154, 2019.

[9] A. Fernández, S. García, F. Herrera, and N. V. Chawla, "SMOTE for Learning from Imbalanced Data: Progress and Challenges, Marking the 15-year Anniversary," *J. Artif. Intell. Res.*, vol. 61, pp. 863–905, 2018.

[10] C. A. G. Lemaitre, F. Nogueira, D. Oliveira, "SMOTE," 2017. [Online]. Available: https://imbalanced-learn.readthedocs.io/en/stable/generated/imblearn.over_sampling.SMOTE.html#r001eabbe5dd7-1. [Accessed: 27-Jul-2020].

[11] N. Griffiths, "How To Fine-Tune Your Neural Network For Your Data: Image Classification," 2019. [Online]. Available: <https://towardsdatascience.com/how-to-fine-tune-your-neural-network-for-your-data-image-classification-d0f01c92300b>. [Accessed: 03-Sep-2020].

[12] E. S. Tellez, S. Miranda-Jiménez, M. Graff, D. Moctezuma, O. S.

²⁴ Es la colaboración o externalización abierta de tareas, en donde trabajadores de sitios como CrowdFlower se encargan de clasificar a cada uno de los tuits, cabe recalcar que cada tuit tuvo que haber sido clasificado por al menos tres personas para tomarla como válida a dicha clase [4].

²⁵ T. Davidson, D. Warmlesley, M. Macy, and I. Weber, "Automated Hate Speech Detection and the Problem of Offensive Language," in *Proceedings of the 11th International AAI Conference on Web and Social Media*, 2017, pp. 512–515.

- Siordia, and E. A. Villaseñor, "A case study of Spanish text transformations for twitter sentiment analysis," *Expert Syst. Appl.*, vol. 81, pp. 457–471, 2017.
- [13] J. Camilo, G. Mejía, F. Alberto, and V. Agudelo, "descubrimiento de conocimiento (KDD) en bases de datos operativas o transaccionales," pp. 56–60, 2017.
- [14] S. A. Phand and J. A. Phand, "Twitter sentiment classification using stanford NLP," *Proc. - 1st Int. Conf. Intell. Syst. Inf. Manag. ICISIM 2017*, vol. 2017-Janua, pp. 1–5, 2017.
- [15] L. Piñón Ferrer, "Minería de datos aplicada a Twitter y análisis de sentimientos mediante algoritmos de inteligencia artificial," 2018.
- [16] S. A. Phand and V. A. Chakkarwar, "Enhanced Sentiment Classification Using GEO Location Tweets," *2018 Second Int. Conf. Inven. Commun. Comput. Technol.*, no. Iccict, pp. 881–886, 2018.
- [17] Apollo, "Sitio web de Spyder," 2019. [Online]. Available: <https://www.spyder-ide.org/>. [Accessed: 09-Jun-2020].
- [18] E. Bisong, *Building Machine Learning and Deep Learning Models on Google Cloud Platform*. 2019.
- [19] R. Kenneth, "Twitter-Scraper," 2020. [Online]. Available: <https://pypi.org/project/twitter-scraper/>. [Accessed: 09-Jun-2020].
- [20] Pandas, "Biblioteca de análisis de datos de Python - pandas: Biblioteca de análisis de datos de Python," 2018. [Online]. Available: <https://pandas.pydata.org/>. [Accessed: 27-Jul-2020].
- [21] E. Loper and K. Ewan, "Kit de herramientas de lenguaje natural - documentación NLTK 3.5," 2009. [Online]. Available: <https://www.nltk.org/>. [Accessed: 27-Jul-2020].
- [22] G. Varoquaux, L. Buitinck, G. Louppe, O. Grisel, F. Pedregosa, and A. Mueller, "Scikit-learn," *GetMobile Mob. Comput. Commun.*, vol. 19, no. 1, pp. 29–33, 2015.
- [23] M. L. Schmid, "Characterising REGEX languages by regular languages equipped with factor-referencing," *Inf. Comput.*, vol. 249, no. January, pp. 1–17, 2016.
- [24] C. Schnober, "Biblioteca Joblib Python," 2019. [Online]. Available: <https://www.admin-magazine.com/HPC/Articles/Parallel-Python-with-Joblib>. [Accessed: 27-Jul-2020].
- [25] Matplotlib, "Matplotlib: Python plotting - documentación de Matplotlib 3.1.1," 2020. [Online]. Available: <https://matplotlib.org/>. [Accessed: 27-Jul-2020].
- [26] S. Han, "Googletrans: Free and Unlimited Google translate API for Python," 2018. [Online]. Available: <https://py-googletrans.readthedocs.io/en/latest/>. [Accessed: 27-Jul-2020].
- [27] X. Deng, Q. Liu, Y. Deng, and S. Mahadevan, "An improved method to construct basic probability assignment based on the confusion matrix for classification problem," *Inf. Sci. (Ny)*, vol. 340–341, pp. 250–261, 2016.
- [28] A. Luque, A. Carrasco, A. Martín, and A. de las Heras, "The impact of class imbalance in classification performance metrics based on the binary confusion matrix," *Pattern Recognit.*, vol. 91, pp. 216–231, 2019.
- [29] A. S. Al Shammari, "Real-time Twitter Sentiment Analysis using 3-way classifier," *21st Saudi Comput. Soc. Natl. Comput. Conf. NCC 2018*, pp. 1–3, 2018.
- [30] D. Mahajan and D. Kumar Chaudhary, "Sentiment Analysis Using Rnn and Google Translator," *Proc. 8th Int. Conf. Conflu. 2018 Cloud Comput. Data Sci. Eng. Conflu. 2018*, pp. 798–802, 2018.
- [31] Y. Al-Amrani, M. Lazaar, and K. E. Elkadiri, "Sentiment analysis using supervised classification algorithms," in *ACM International Conference Proceeding Series*, 2017, vol. Part F1294.
- [32] J. A. Rimassa, "El análisis de opiniones en la predicción política basados en Twitter. Un nuevo enfoque," p. 102, 2019.
- [33] B. Herrera Flores, "Polaridad de las opiniones sobre un personaje público en el Ecuador," vol. V, no. 2, pp. 27–32, 2018.
- [34] W. Elmenreich, J. A. T. Machado, and I. J. Rudas, *Intelligent systems at the service of mankind*, vol. 1, no. January. 2016.
- [35] M. C. Justicia de la Torre, *Nuevas Técnicas De Minería De Textos: Aplicaciones*. 2017.
- [36] D. Rubio Cortés, "Herramienta para el análisis de opiniones y sentimientos sobre Twitter," 2017.
- [37] J. A. López-Palma and M. Estévez-Crespo, "MOAS-Les, herramienta para el análisis de sentimientos de textos en idioma español," pp. 1–20, 2016.
- [38] S. V. Luis Yayir, "Evaluación de Algoritmos de Clasificación para el Minado de Opinión en Twitter," *Rev. la Univ. Señor Sipán*, 2019.
- [39] P. E. Rom and M. G. Armentano, "Herramienta integral de análisis de sentimientos en redes sociales," 2018.
- [40] J. N. Briones, "Análisis de sentimientos en sistemas de ticketing IT," 2019.
- [41] O. Hidalgo, R. Jaimes, E. Gomez, and S. Lujan-Mora, "Sentiment analysis applied to the popularity level of the ecuadorian political leader rafael correa," *Proc. - 2017 Int. Conf. Inf. Syst. Comput. Sci. INCISCOM 2017*, vol. 2017-Novem, pp. 340–346, 2018.
- [42] G. A. Ruz, P. A. Henríquez, and A. Mascareño, "Sentiment analysis of Twitter data during critical events through Bayesian networks classifiers," *Futur. Gener. Comput. Syst.*, vol. 106, pp. 92–104, 2020.
- [43] H. Rehioui and A. Idrissi, "New clustering algorithms for twitter sentiment analysis," *IEEE Syst. J.*, vol. 14, no. 1, pp. 530–537, 2020.
- [44] A. E. Vélez Bravo, "Aplicativo para detectar conductas violentas en Twitter, a través de análisis de sentimientos," 2020.
- [45] Y. Gao and S. Wang, "Application & Comparison of several sentiment analysis platforms with open source review dataset," *ACM Int. Conf. Proceeding Ser.*, no. 2011, 2019.
- [46] S. A. López and J. J. Cuadrado-Gallego, "Supervised learning methods application to sentiment analysis," *ACM Int. Conf. Proceeding Ser.*, no. 3, 2019.
- [47] Q. Li, Q. Zhang, and L. Si, "TweetSenti: Target-dependent tweet sentiment analysis," *Web Conf. 2019 - Proc. World Wide Web Conf. WWW 2019*, pp. 3569–3573, 2019.
- [48] S. Alashri, S. Alzahrani, M. Alhoshan, I. Alkhanen, S. Alghunaim, and M. Alhassoun, "Lexi-augmenter: Lexicon-based model for tweets sentiment analysis," *Proc. - 22nd IEEE Int. Conf. Comput. Sci. Eng. 17th IEEE Int. Conf. Embed. Ubiquitous Comput. CSE/EUC 2019*, pp. 7–10, 2019.
- [49] R. N. Montufar Mercado, "Automatic Cyberbullying detection in Spanish-Language Social Networks using Sentiment Analysis Techniques," 2019.
- [50] L. Talamé, A. Cardoso, and M. Amor, "Comparación de herramientas de procesamiento de textos en español extraídos de una red social para Python," pp. 53–67.
- [51] A. Cardoso, L. Talame, M. Amor, and C. Neil, "Minería de Opiniones: Análisis de Sentimientos en una Red Social," 2019.
- [52] M. Ruiz, "Análisis de Sentimientos a través de Twitter," 2019.
- [53] S. A. El Rahman, F. A. Alotaibi, and W. A. Alshehri, "Sentiment Analysis of Twitter Data," in *2019 International Conference on Computer and Information Sciences, ICCIS 2019*, 2019.
- [54] M. I. Sajib, S. Mahmud Shargo, and M. A. Hossain, "Comparison of the efficiency of machine learning algorithms on twitter sentiment analysis of pathao," *2019 22nd Int. Conf. Comput. Inf. Technol. ICCIT 2019*, pp. 1–6, 2019.
- [55] A. Trujillo and M. Orellana, "Evaluación de técnicas de procesamiento de lenguaje natural para textos cortos en lenguaje español," 2018.
- [56] B. Lin, F. Zampetti, G. Bavota, M. Di Penta, M. Lanza, and R. Oliveto, "Sentiment analysis for software engineering: How Far Can We Go?," in *Proceedings of the 40th International Conference on Software Engineering*, 2018, pp. 94–104.
- [57] T. Chen, R. Xu, Y. He, and X. Wang, "Improving sentiment analysis via sentence type classification using BiLSTM-CRF and CNN," *Expert Syst. Appl.*, vol. 72, pp. 221–230, 2017.
- [58] I. El Alaoui, Y. Gahi, and R. Messoussi, "Big data quality metrics for sentiment analysis approaches," *ACM Int. Conf. Proceeding Ser.*, pp. 36–43, 2019.
- [59] P. D. Leonardo, "Análisis de sentimientos. Aplicación sobre textos en redes sociales," 2019.
- [60] S. Saini, R. Punhani, R. Bathla, and V. K. Shukla, "Sentiment Analysis on Twitter Data using R," *2019 Int. Conf. Autom. Comput. Technol. Manag. ICACTM 2019*, pp. 68–72, 2019.
- [61] V. Vyas and V. Uma, "An Extensive study of Sentiment Analysis tools and Binary Classification of tweets using Rapid Miner," *Procedia Comput. Sci.*, vol. 125, pp. 329–335, 2018.
- [62] R. Borja-Robalino, A. Monleón-Getino, and J. Rodellar, "Estandarización de métricas de rendimiento para clasificadores Machine y Deep Learning," no. June, 2020.
- [63] J. Calloni *et al.*, "Modelo para Analizar Mensajes y Detectar Actitudes Peligrosas a través de Análisis de Sentimientos con Algoritmos de Aprendizajes," *XIX Work. Investig. en Ciencias la Comput.*, pp. 100–104, 2017.
- [64] K. Sailunaz and R. Alhaji, "Emotion and sentiment analysis from Twitter text," *J. Comput. Sci.*, vol. 36, p. 101003, 2019.
- [65] E. W. Pamungkas and D. G. P. Putri, "Word sense disambiguation for lexicon-based sentiment analysis," *ACM Int. Conf. Proceeding Ser.*, vol. Part F1283, pp. 442–446, 2017.
- [66] R. Romero, "Entrevista a Dr. Paul Palacios - Ing Celia Jara

- Galdeman," *Google Drive*, 2020. [Online]. Available: <https://drive.google.com/file/d/1gNqSMraM3y-aaevO4w7Cbps1MeIJdNKW/view>. [Accessed: 01-Sep-2020].
- [67] Y. Castán, "Metodo Cientifico y Sus Etapas," *Castán, Yolanda. Inst. Aragon. Ciencias La Salud*, vol. 2, pp. 1–6, 2006.
- [68] C. E. Montes, *Metodología de investigación tecnológica*. .
- [69] M. Petticrew and H. Roberts, *Systematic Reviews in the Social Sciences*. 2006.
- [70] M. del Interior, "Migración – Ministerio de Gobierno," *Cifras entras y salidas migración*, 2019. [Online]. Available: <https://www.ministeriodegobierno.gob.ec/migracion/>. [Accessed: 18-Jun-2020].
- [71] WELCOMEAI, "Crowdfower," 2019. [Online]. Available: <https://www.welcome.ai/crowdfower>. [Accessed: 16-Aug-2020].
- [72] O. M. Cumbicus-Pineda, P. F. Ordoñez-Ordoñez, L. A. Neyra-Romero, and R. Figueroa-Diaz, "Automatic categorization of tweets on the political electoral theme using supervised classification algorithms," in *Communications in Computer and Information Science*, 2019, vol. 895, pp. 671–682.
- [73] G. Campoverde and R. Romero, "Entrevista a Psicóloga," *Google Drive*, 2020. [Online]. Available: <https://drive.google.com/drive/folders/1puJNdQ2vECT-Ry5pVNZp6sJacu5vQOIu>. [Accessed: 14-Aug-2020].
- [74] C. Mart, "Análisis de Sentimientos en Twitter : El bueno , el malo y el > :(" 2016.
- [75] D. Yang, A. N. Zhang, and W. Yan, "Performing literature review using text mining, Part I: Retrieving technology infrastructure using Google Scholar and APIs," *Proc. - 2017 IEEE Int. Conf. Big Data, Big Data 2017*, vol. 2018-Janua, pp. 3290–3296, 2017.
- [76] J. Cardenas, "Odd ratio: qué es y cómo se interpreta," 2016. [Online]. Available: <http://networkianos.com/odd-ratio-que-es-como-se-interpreta/>. [Accessed: 03-Sep-2020].
- [77] W. J. Wilbur and K. Sirotkin, "The automatic identification of stop words," *J. Inf. Sci.*, vol. 18, no. 1, pp. 45–55, 1992.

Anexo 13

A continuación, se adjunta el anteproyecto del presente TT.



Universidad
Nacional
de Loja

Facultad de Energía, las Industrias y los Recursos Naturales no Renovables

Carrera de Ingeniería en Sistemas

Análisis de sentimientos en Twitter para descubrir contenido xenófobo hacia los inmigrantes venezolanos en Ecuador

Línea de investigación: Sistemas Inteligentes

PROYECTO DE TITULACIÓN EN
INGENIERÍA EN SISTEMAS.

Autor:

✉ ORCID, Raúl Ramiro Romero Vega, raul.romero@unl.edu.ec

Tutor:

- Oscar Miguel Cumbicus Pineda, Mg.Sc.



Carrera de Ingeniería en
Sistemas/Computación.

**LOJA - ECUADOR
2020**

**Análisis de sentimientos en Twitter
para descubrir contenido xenófobo
hacia los inmigrantes venezolanos
en Ecuador**

Línea de investigación: Sistemas Inteligentes

1. Problemática

1.1. Situación Problemática

Con el surgimiento de la Web 2.0, las personas tienen la libertad de crear y compartir su propio contenido públicamente en las redes sociales, particularmente en la plataforma de microblogging Twitter [1], que permite compartir mensajes de hasta 280 caracteres llamados tuits [2]. Según Statista [3], a partir del primer trimestre de 2019, Twitter promedió 330 millones de usuarios activos mensuales, aunque en números está por debajo de sus competidores, Twitter tiene otra esencia, permite describir lo que se está haciendo y la difusión de noticias; se caracteriza por la crítica en masas, en donde expresan su opinión y puntos de vista acerca de temas sociales, políticos, humanitarios, etc., generando información de gran interés para ser analizada.

Según Valdez-Apolo [4], manifiesta que debido a esta libertad para hacer públicas las ideas y pensamientos, se ha registrado un incremento del discurso del odio en las redes sociales, enfatizando que al haber un aumento en la difusión de mensajes racistas, xenófobos, de intolerancia, o que señalen a los otros como una amenaza, crece exponencialmente el rechazo y la posibilidad de que se comentan delitos de odio.

Según la Organización Internacional para las Migraciones [5], Ecuador es el tercer país con el mayor número de inmigrantes venezolanos, alberga más de 250.000, además, de acuerdo a una publicación de Hopenhayn [6], un 8% de población indígena se encuentra en Ecuador y, de población negra, mestiza afrolatina y afrocaribeña existe un 10% en Venezuela, e indica que a principios del nuevo milenio los pueblos indígenas, afrolatinos y afrocaribeños presentan los peores indicadores económicos y sociales, mostrándose como discriminación étnica y racial, siendo estos indicadores la base de los sentimientos xenófobos entre los países de la región.

Respecto a estos indicadores, Ecuador es un país expuesto a la xenofobia en su población, así como lo enfatiza la Ing. Celia Jara Galdeman, gestora de la carrera de Trabajo Social de la UNL, a través de una entrevista Anexo II, menciona que la xenofobia genera la vulneración de los derechos, afectando directamente a las personas, el no conseguir un trabajo y no poder acceder a los servicios como la salud y la educación, por el hecho de ser de otro lugar. Existiendo también el cometimiento de delitos de odio. Se consolida esta afirmación con hechos ya registrados, como es el caso de la violenta reacción que se produjo principalmente en Ibarra como consecuencia del asesinato de

Diana Ramírez, que fue asesinada en la calle por su pareja de nacionalidad venezolana; provocando que una turba enardecida, busque a los venezolanos en las calles, hoteles y residencias, hasta llegar al albergue municipal que aloja a los migrantes, echándolos del lugar y al grito de “fuera venezolanos” quemaron colchones y sus pertenencias [7].

Una de las formas de prevenir estos delitos de odio, es detectando a tiempo los discursos xenófobos en la población, siendo esta una tarea difícil de conocer a través de las técnicas tradicionales como las encuestas, debido a los estigmas que existen entorno al racismo y la xenofobia, conocido como sesgo de deseabilidad social [4].

Sin embargo, de acuerdo a la investigación realizada en las redes sociales por Valdez-Apolo [4], mediante la recolección y preprocesamiento de una muestra de tuits y a través del Procesamiento del Lenguaje Natural (PLN) pudo determinar la polaridad de sentimientos hacia migrantes y refugiados, como positivos, negativos y neutros, dando como pauta de que mediante el análisis de sentimientos se posibilita determinar la existencia de xenofobia presente en las opiniones.

1.2. Problema de Investigación

De acuerdo al planteamiento de la problemática, surgen interrogantes acerca de que si a través del análisis de sentimientos, será posible detectar opiniones con contenido xenófobo en Twitter y determinar su existencia en Ecuador hacia inmigrantes venezolanos. Considerando esto se puede deducir la siguiente pregunta de investigación:

¿Existen tuits con contenido xenófobo hacia los inmigrantes venezolanos en Ecuador?

2. Justificación

El presente trabajo de titulación (TT), busca determinar la existencia de sentimientos xenófobos en la red social Twitter hacia los inmigrantes en Ecuador, específicamente a venezolanos que hoy en día representan el 77% de extranjeros que ingresan al país. Aportando información relevante que puede ser utilizada por algunas organizaciones como: la Comisión Ecuémica de los Derechos Humanos (CEDHU), dedicada a la promoción de la justicia social y el empoderamiento de los sectores desprotegidos en Ecuador; de la misma manera se ha hecho presente la Organización de las Naciones Unidas (ONU), en respuesta a contrarrestar el discurso xenófobo en el Ecuador, mediante el lanzamiento de una campaña de concientización “Abrazos que Unen” que busca mitigar los discursos y delitos del odio hacia los refugiados y migrantes en el país.

La CEDHU también enfatiza que la constitución del estado ecuatoriano en el numeral 2 del Art. 11 prohíbe expresamente cualquier tipo de discriminación, ya sea por su lugar de nacimiento o su condición migratoria, es por eso que conociendo la existencia de mensajes xenófobos en las redes sociales, se ayuda a la toma de decisiones para el estado, el mismo que está en la obligación de prevenir y tutelar los derechos humanos de todas las personas, en especial aquellas que pueden ser víctimas de discriminación y violentadas en razón de su nacionalidad.

El Dr. Paúl Palacios, especialista de la Unidad de Bienestar Universitario en el Área de Psicología de la UNL, de acuerdo a una entrevista Anexo II, menciona que mediante el presente TT se podría trazar una propuesta que permita que la gente cambie de actitud, porque de acuerdo a él, la xenofobia es un problema de actitud, que así mismo genera muchos problemas no solamente a nosotros sino fundamentalmente a ellos que necesitan vivir de forma digna, “no es correcto que muchos de ellos por la xenofobia tengan que estar sin empleo, sin educación, sin trabajo y en condiciones sumamente precarias, tirados en las calles, niños abandonados; entonces yo creo que se puede hacer bastante a través de Twitter para que la gente cambie de actitud, y romper esa xenofobia que hasta ahora es muy violenta”.

Por otra parte, se destaca que este TT mediante la evaluación de las opiniones en Twitter a través del Procesamiento de Lenguaje Natural (PLN) pretende determinar la existencia de sentimientos xenófobos a extranjeros en nuestro país, información que puede llegar a contribuir a aquellas organizaciones que defienden los derechos humanos, para sus diferentes actividades e incluso para la toma de decisiones, siendo esto

favorable para el bienestar de la sociedad, ya que al detectar a tiempo los sentimientos xenófobos y su nivel de presencia en las personas se pueden evitar el cometer delitos de odio y el recibir sanciones, ya que según el Art. 177 del COIP (Código Orgánico Integral Penal) [8], determina que la persona que cometa actos de violencia física o psicológica de odio, contra una o más personas en razón de su nacionalidad será sancionada con pena privativa de libertad de uno a tres años.

De igual modo, también se contribuye a la educación, ya que plantea las bases necesarias para analizar sentimientos “complejos”, por ejemplo, la xenofobia específicamente se trata de una fobia y no de un solo sentimiento en particular, es por eso, que es necesario analizar todos los sentimientos que están entorno a esta, como pueden ser: el odio, repugnancia y hostilidad hacia lo extranjero [9], [10], [11], ya que su correcta asociación posibilitará conocer la existencia de una fobia dentro de una opinión, llegando a ser un aporte importante para el desarrollo de otras investigaciones.

Así mismo, la Ing. Celia Jara Galdeman, gestora de la carrera de Trabajo Social de la UNL, de acuerdo a una entrevista Anexo II, menciona la importancia que tiene la realización del presente TT especialmente para las universidades, “ya que sería una fuente de información para poder proponer alternativas de solución, de hecho, conoceríamos en este caso el origen de las personas, de cuáles son las expresiones y sobre eso, actuar con las propuestas”.

Por otra parte, el presente TT se orienta de acuerdo a algunas líneas de investigación, como son: a nivel internacional está enmarcado al Objetivo de Desarrollo Sostenible (ODS) N° 10 “Reducir la desigualdad en los países y entre ellos” propuesto por la Organización de las Naciones Unidas (ONU) [12], a nivel nacional se realiza bajo el lineamiento de las TIC’s en la Economía, Cultura y Sociedad del “Libro Blanco” 2019 [13], además de su aplicación al Territorio y a la Inclusión que constan en el acuerdo Nro. SENECYT-2018-028 [14], y localmente en la línea de investigación de Sistemas Inteligentes de la Carrera de Ingeniería en Sistemas de la Universidad Nacional de Loja (UNL) [15].

3. Objetivos

3.1. General

Descubrir tuits con contenido xenófobo a inmigrantes venezolanos en Ecuador mediante el análisis de sentimientos en Twitter.

3.2. Específicos

- Realizar una revisión bibliográfica acerca del análisis de sentimientos en Twitter.
- Aplicar una metodología para el análisis de sentimientos.
- Interpretar los resultados obtenidos en el análisis de sentimientos.

4. Alcance

- Realizar una revisión bibliográfica acerca del análisis de sentimientos en Twitter.
 - Realizar revisión bibliográfica, basada en las fases de la metodología de RSL de Bárbara Kitchenham.
 - Determinar metodología para el análisis de sentimientos.
 - * Identificar el lenguaje de programación, algoritmos, herramientas y software en general necesario para realizar cada una de las fases de la metodología de análisis de sentimientos.
- Aplicar metodología para el análisis de sentimientos.
 - Identificar el intervalo de tiempo más conveniente para delimitar la búsqueda y extracción de los tuits.
 - Ejecutar las fases de la metodología seleccionada en el primer objetivo específico.
- Interpretar los resultados obtenidos en el análisis de sentimientos.
 - Analizar e identificar los mejores algoritmos para el análisis de sentimientos.
 - Interpretar los resultados obtenidos.
 - Dar contestación a la pregunta de investigación.

5. Marco Teórico

En esta sección se presentan las definiciones de aquellos conceptos que aportan al cumplimiento de los objetivos y contribuyen al conocimiento teórico de los mismos; junto con el establecimiento de teorías y hallazgos de trabajos relacionados al presente TT.

5.1. Discursos del odio

Los discursos del odio se refieren a aquellas expresiones discriminatorias o que provocan violencia a causa del odio racial, xenofobia, orientación sexual, y cualquier otra forma de discriminación, en donde las personas son el actor principal encargados de difundir los mensajes discriminatorios hacia otra persona o grupo de personas, provocando violencia, odio y aborrecimiento hacia los demás, en consecuencia, de su diferente nacionalidad. Tienen la capacidad de propagarse mediante cualquier medio de comunicación, ya sea vía oral, escrita, por medios televisivos, internet, etc., en donde buscan apelar a la emoción más que a la razón; una de las maneras de divulgarse son los medios públicos, a través de expresiones sutiles en las que demuestran cierta actitud de dominio de uno sobre otro y de esta forma silenciar a determinados grupos sociales [16].

Existe una preocupación aún mayor, ya que hoy en día estos discursos tienen como principal y más grande medio de propagación a la internet, concretamente a las redes sociales, en donde es aún más difícil de controlar e identificar responsables [17].

5.2. Las redes sociales y los discursos del odio

La influencia de la internet y las redes sociales entorno a los discursos del odio, pueden llegar a tener múltiples características, de forma resumida se denota que, generan impunidad al responsable de propagar estos mensajes y crean un fenómeno descontrolado y más dañino. A continuación, de manera textual se presentan las características de los discursos del odio en las redes sociales [16]:

- La comunicación es masiva y descentralizada.
- Las redes tienen un enorme potencial multiplicador.

- Los contenidos permanecen indefinidamente si no son borrados.
- Los contenidos pueden saltar de una plataforma a otra.
- El uso de pseudónimos y el anonimato están muy extendidos.
- Son un medio de comunicación “sin fronteras”.
- La sensación de “virtualidad” desinhibe.

Las redes sociales además de convertirse en un medio o espacio de comunicación incivilizado, los discursos del odio pueden causar en las personas efectos dañinos. A continuación, de manera textual se presentan los efectos dañinos de los discursos del odio en las redes sociales [16]:

- Daño emocional o psicológico a las víctimas de amenazas o acoso, por motivos de odio e intolerancia.
- Erosión de la dignidad y la reputación de individuos y colectivos.
- Perpetuación de estereotipos discriminatorios, deshumanización y estigmatización de colectivos.
- Reducción de empatía hacia los colectivos deshumanizados.
- Genera el caldo de cultivo propicio para que se produzcan delitos de odio y actos discriminatorios.

Según Bustos-Martínez [17], en una investigación de la Universidad de Oxford se cuantificó que uno de cada 15.000 tuits escritos en inglés, contenían insultos racistas. Entre los discursos del odio más preocupantes que se difunden en las redes sociales con todas las características ya mencionadas, es la xenofobia, presente en las opiniones difundidas por una o un grupo de personas con la intención de rechazo. Como tal, representa un indicador que puede también ser encontrado en Ecuador.

En respuesta a este incremento de sentimientos xenófobos en redes sociales, los organismos internacionales se pronuncian mediante la elaboración de informes en donde resaltan la necesidad de prevenir y castigar los discursos de odio que se difunden rápidamente en las redes sociales, entre estas, Twitter.

5.3. Las redes sociales y la xenofobia

De acuerdo a Bustos-Martínez [17], menciona que a pesar de que el mundo tecnológico ha traído consigo una fácil y rápida comunicación a nivel global, lamentablemente también nos expone a riesgos y amenazas, en relación a problemas como la xenofobia, presentes en la internet. Como un intento de mitigar esta ola de discriminación en los medios digitales, se han creado organizaciones como el Alto Comisionado de las Naciones Unidas para los Refugiados (ACNUR) que ha propuesto planes de acciones que vayan en contra de este problema social presente mayoritariamente en las redes sociales.

La presencia de estos mensajes discriminatorios conlleva a repercusiones que pueden provocar tanto daños directos como indirectos, resultando en ambos casos que las víctimas pueden sentirse ofendidas por estos discursos xenófobos. Cabe destacar que actualmente existe un auge de estos comportamientos discriminatorios, como pueden ser las amenazas, las injurias y la discriminación, en el contexto de los ámbitos del racismo, xenofobia e ideología.

Existen medios de comunicación que han participado exponiendo estos delitos de odio racial y xenófobo que están presentes en las redes sociales, he aquí un ejemplo:

En el artículo de periódico [18], titulado “La xenofobia en Ecuador empuja a migrantes venezolanos a salir del país”, se cita textualmente la narración de los hechos suscitados el domingo 20 de enero de 2019, en la que una turba irrumpió a la fuerza en un pequeño conjunto residencial en Ibarra, para desalojar a inmigrantes venezolanos. “Cuando nos asomamos por el balcón vimos que venía gente corriendo, tal vez mil personas”, dice Rafael Aular, un veterinario de 30 años que vive hace año y medio en la ciudad de poco más de doscientos mil habitantes. Aular dice que él y los otros cinco hombres que estaban en el departamento (junto a dos mujeres y un par de niños) empezaron a trancar las puertas, pero todo sucedió muy rápido. “De una patada tumbaron el portón”, recuerda.

Daniel García, un comerciante de 25 años que vive en el departamento, dice que después del golpe escuchó a la muchedumbre entrar. “Gritaban: ‘Mátenlos, asesinos’”, recuerda. Otro inquilino llamado Jesús Sánchez escuchó que una voz ordenaba desde la vereda: “Sáquenlo, sáquenlo para quemarlo”. En distintos puntos de Ibarra, grupos similares invadieron y saquearon residencias y hostales donde vivían grupos de venezolanos.

Estos ataques fueron el clímax de un fin de semana enrarecido por la violencia y la xenofobia en Ecuador. La noche anterior, un video que mostraba a un hombre asesinando a puñaladas a una mujer embarazada había conmocionado al país. La filmación se propagó en redes sociales con un detalle incendiario: el asesino era venezolano...

El principal medio de difusión de este tipo de noticias son las redes sociales, que permiten alterar la información para crear mayor conmoción a sus lectores; ya que, según la ministra del Interior de Ecuador, María Paula Romo, el sujeto actuó por celos. “Es un femicidio, es violencia machista”, dijo vía WhatsApp. Pero en las redes sociales y en muchos medios no era un problema de violencia de género, sino de pasaporte.

Dado esto se puede constatar que las redes sociales no solo son un gran medio de comunicación, sino que en ocasiones permiten desinformar e incluso permiten el anonimato, es conocido saber que las personas que difunden estos mensajes de odio y amenazas se ocultan bajo cuentas falsas.

Este tipo de acontecimientos generan gran cantidad de información en las redes sociales, concretamente en Twitter que se caracteriza por la crítica en masas y la difusión de noticias, en donde expresan su opinión acerca de temas sociales, políticos, humanitarios, etc., generando información textual de gran interés, que siendo procesada puede ser de mucha utilidad, de acuerdo a los fines del investigador.

5.4. Minería de datos

De acuerdo a Doctor y Pino [19], la minería de datos es el proceso de obtener conocimiento nuevo a partir de grandes cantidades de datos, que contribuyen en muchas áreas, como son la estadística, el aprendizaje de máquinas, recuperación de la información, reconocimiento de patrones y bioinformática. Su objetivo es el descubrimiento de patrones, perfiles, anomalías y tendencias a través del análisis de los datos.

Desde el punto de vista de las metodologías de minería de datos y modelos de procesos, el año 2000 marcó el hito más importante: Cross-Industry de Procesos Estándar para la Minería de Datos (CRISP-DM) fue propuesto por primera vez. CRISP-DM fue la metodología más ampliamente utilizada para el desarrollo de proyectos de minería de datos, pero aun así tiene sus desventajas como al hecho de que sólo define qué hacer y no cómo hacer.

Es por eso que se dio la necesidad de construir una nueva metodología para ayudar a los usuarios a evitar muchos errores de minería de datos común; CRISP-DM fue como el enfoque central del diagrama de la evolución y la metodología conocida como KDD (Descubrimiento de Conocimiento en Bases de Datos) se la toma como el enfoque inicial para variaciones como la minería de textos, la misma que se explicará más adelante [20].

Mariscal, Marbán y Fernández [20], representan el proceso KDD como se muestra

en la Figura 5.1.

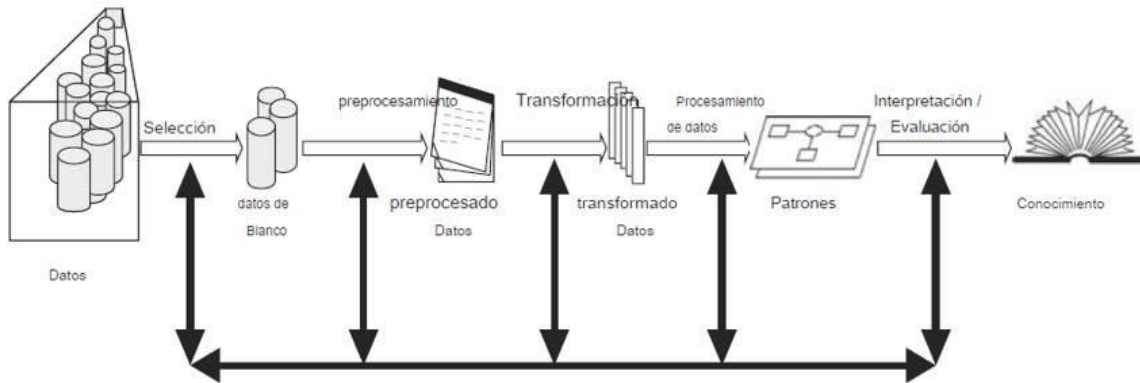


Figura 5.1: Descripción general de los pasos que constituyen el descubrimiento de conocimiento en bases de datos de proceso (KDD)

Las principales técnicas en este campo incluyen clasificación y predicción, clustering, detección de outliers, reglas de asociación, análisis secuencial, análisis de series temporales, redes neuronales, árboles de decisión, etc. También son frecuentes técnicas más novedosas como el análisis de redes sociales o el análisis de sentimientos.

La minería de datos incluye muchas áreas diferentes en función del tipo de datos a analizar. Entre estas áreas se encuentra la minería de textos, en la que los datos son documentos de texto, partiendo por esta razón de información muy poco estructurada [19].

5.5. Minería de textos

5.5.1. Descubrimiento de Conocimiento en Textos (KDT)

Según Justicia de la Torre [21], el descubrimiento de conocimiento se ha venido realizando sobre los datos almacenados en bases de datos estructuradas. No obstante, la mayoría de la información disponible a tratar está en formato textual. Se define al descubrimiento de conocimiento como la extracción de información previamente desconocida y potencialmente útil a partir de los datos, el presente TT adopta esta definición considerando que los datos son textuales.

Los datos textuales no estructurados son los que hacen emerger una serie de problemas que necesitan un tratamiento adicional. Dichos problemas son:

- La falta de estructura del texto.
- La naturaleza heterogénea y distribuida de los documentos; las fuentes de textos pueden ser tan diversas como podamos imaginar: bases de datos documentales, redes sociales, censos, páginas web, informes empresariales, publicaciones, correos electrónicos, etc.
- El multilingüismo o plurilingüismo puede estar presente tanto en diferentes conjuntos de documentos como dentro de una misma colección de textos.

Por lo tanto, el proceso KDT agrupa a diferentes ámbitos de conocimiento, como son:

- Recuperación de Información (para filtrar y reunir documentos adecuados).
- Extracción de Información (que selecciona hechos específicos sobre tipos de entidades y relaciones de interés).
- Procesamiento del Lenguaje Natural (para realizar el preprocesamiento y etiquetado de los textos).
- Minería de Datos (para descubrir asociaciones desconocidas entre hechos desconocidos).

Del mismo modo, Justicia de la Torre [21] plantea una serie de fases a seguir para la realización del proceso KDT.

5.5.2. Fases del proceso KDT

Definición de conceptos: Estos conceptos son escogidos según el objetivo de cada investigador. Por ejemplo, en el presente TT se tiene que buscar los conceptos claves del análisis de sentimientos en la red social Twitter, entorno a los discursos del odio como la xenofobia.

Recopilación de información: El objetivo de esta etapa es recopilar la información o datos que serán objeto de estudio, esta recopilación se da a través de herramientas de recopilación, como la extracción de textos de páginas web a través de API's o Web Scraping.

Pre-Procesamiento: El texto no tiene una estructura adecuada para el descubrimiento de conocimiento, por lo que se necesita asegurar la homogeneidad del texto, es decir, que no existan conceptos o caracteres que distorsionen posteriormente la detección de patrones.

Transformación: Se procede a dar la estructura necesaria al texto para la posterior detección de patrones o minería de texto, a continuación, se mencionan los procesos clave:

- **Lematizado:** Es el proceso de transformar las variaciones de las palabras con morfemas a su raíz (lexema), por ejemplo, el caso de la palabra “comidita” en la cual el morfema es “ita” su lexema por ende será “comida” debe ser transformada a su lexema, con el fin de evitar tener variantes de las palabras.
- **Etiquetado:** el etiquetado gramatical o desambiguación, es el proceso de clasificar una palabra en función tanto de su definición como de su contexto, es decir, su relación con las palabras adyacentes y relacionadas en una frase, oración o párrafo. Este se logra a través de clasificar palabras como sustantivos, verbos, adjetivos, adverbios, etc.
- **Tokenizado:** Es la acción de dividir el texto en elementos llamados tokens, éstos son elementos indivisibles, por ejemplo, las frases se separan en palabras (tokens) con el fin de construir una matriz de palabras, en donde los encabezados de cada columna serán las palabras existentes dentro del corpus de los tweets.

Minado de texto: Esta es una de las etapas más amplias, caracterizándose en el descubrimiento de conocimiento, el cual se puede dar a través de detección de patrones, representaciones vectoriales, modelos de aprendizaje supervisado o no supervisado entre otros métodos, la elección del método dependerá del objetivo del investigador, en este capítulo se realizó una revisión de algunos métodos que fueron aplicados en la investigación.

Interpretación de resultados: En esta etapa se da paso a interpretar y validar el conocimiento obtenido tras realizar el proceso, sin embargo, puede no ser la última etapa, esto dependerá de la validación del contenido en caso de ser rechazado por el investigador podría resultar en el retroceso en el proceso.

5.6. Diferencias entre la minería de datos y la minería de textos

De acuerdo a las características ya mencionadas de ambas minerías [21], quizá se podría situar a la minería de textos dentro de la minería de datos, pero en realizar existen diferencias entre ambas metodologías, como la recuperación de la información, la extracción de la información y el procesamiento del lenguaje natural.

A continuación, en la Tabla 5.1 de acuerdo a Justicia de la Torre [21], se plantea un cuadro comparativo de las metodologías empleadas para la minería de datos (KDD) y la minería de textos (KDT).

Tabla 5.1: Cuadro comparativo de las metodologías KDD y KDT

KDD	KDT
Comprensión del dominio de la aplicación	Definición de los conceptos de interés
Selección de un conjunto de datos objetivos	Obtención de los textos mediante técnicas de recuperación de la información o de forma manual
Limpieza, pre.procesamiento y transformación de los datos	Descripción de los conceptos y representación y transformación de los textos: eliminar stopwords...
Desarrollo de los modelos e hipótesis	Identificación de los conceptos de interés en la colección de textos
Minería de datos	Minería de textos
Interpretación de los resultados	Interpretación de los resultados

5.7. Procesamiento de Lenguaje Natural (PLN)

De acuerdo a Bock y Garnsey [22], el PLN emplea técnicas computacionales con el propósito de aprender, comprender y producir contenido en lenguaje humano. Los primeros enfoques computacionales para la investigación del lenguaje se centraron en automatizar el análisis de la estructura lingüística del lenguaje y desarrollar tecnologías básicas como la traducción automática, el reconocimiento del habla y la síntesis del habla.

Los investigadores de hoy refinan y hacen uso de tales herramientas en aplicaciones del mundo real, buscando en las redes sociales información sobre salud o finanzas, e identificando sentimientos y emociones hacia productos y servicios.

Dichas herramientas para el PLN, contribuyen al análisis e identificación de los sentimientos existentes entorno al posible contenido xenófobo presente en la red social Twitter.

5.8. Análisis de sentimientos

Del mismo modo, Bock y Garnsey [22] destacan que gran parte del trabajo en PLN se ha centrado en el análisis de sentimientos, es decir, en la identificación de orientación positiva o negativa del lenguaje textual y la identificación de estados de creencia, por ejemplo, la creencia comprometida, creencia no comprometida, o neutralidad de una oración, sobre la base de información léxica y sintáctica.

Tanto el sentimiento como la creencia constituyen actitudes hacia eventos y proposiciones, aunque el sentimiento también puede referirse a actitudes hacia objetos como personas, organizaciones y conceptos abstractos. La detección de sentimientos y emociones en el texto requieren de un análisis léxico de cada palabra y de toda la oración. El sentimiento se puede expresar con palabras que transmitan orientación positiva o negativa: por ejemplo, "triste", "preocupado", "difícil" y "débil" son todas palabras con orientación negativa, mientras que "cómodo", "importante", "exitoso", e "interesante" transmiten un sentimiento positivo.

Los enfoques más sofisticados para el análisis de sentimientos también buscan identificar al autor de determinada publicación (o tuit), así como el objeto del sentimiento: por ejemplo, quién es positivo sobre qué persona, país, actividad o concepto.

5.9. Herramientas para el análisis de sentimientos

Según Medina-Merino [23], para la realización del procesamiento de lenguaje natural y análisis de sentimientos, se determina que son necesarios algunos lenguajes de programación como R y Python, que se detallan a continuación:

- **R:** Se trata de un lenguaje de programación principalmente estadístico, que con la instalación de paquetes permite la realización de gran variedad de técnicas de procesamiento de lenguaje natural y análisis de sentimientos, que en este TT se aplicarán en los tuits recolectados.
- **Python:** Python también contribuye como un lenguaje de programación, que aporta con un enorme abanico de librerías para realizar machine learnig, en la que puntualmente se requiere explotar aquellas herramientas para el procesamiento de lenguaje natural y análisis de sentimientos.

Según Jongeling et al. [24], realizan una evaluación de las herramientas más afines para el análisis de sentimientos, en donde se centra en aquellas de código abierto aplicadas para textos cortos como tuits. A continuación, se presentan las más relevantes:

- **NLTK:** El Natural Language Toolkit (NLTK) se considera la plataforma líder para el análisis de texto del lenguaje humano, por lo tanto, aporta significativamente al Procesamiento de Lenguaje Natural con Python, consta de un conjunto

de bibliotecas de procesamiento de texto para la clasificación, tokenización, derivación, etiquetado, análisis y razonamiento semántico; es decir, es una herramienta fundamental para el tratado de los tuits obtenidos durante la recolección de los datos.

- **Stanford NLP:** El Grupo de Procesamiento del Lenguaje Natural (PLN) en la Universidad de Stanford, ofrece un kit de herramientas de procesamiento de lenguaje natural, integrado en el software Stanford CoreNLP, el mismo que permite obtener la forma básica de las palabras, normalizar fechas, horas y cantidades numéricas, indican sentimientos, etc. Dicho juego de herramientas de PLN permite un análisis gramatical completo de los tuits recolectados previamente.
- **Sentistrength:** Es un software gratuito (para el sector educativo) capaz de realizar un análisis automático de sentimientos de alrededor de 16000 textos cortos de redes sociales por segundo, se basa en dos fortalezas de sentimiento.
 - -1 (no negativo) a -5 (extremadamente negativo)
 - 1 (no positivo) a 5 (extremadamente positivo)

Según investigaciones de psicología, se han revelado que los humanos procesamos sentimientos positivos y negativos en paralelo, es por eso que Sentistrength utiliza ambas fortalezas, lo que esto lo lleva a tener una precisión a nivel humano en cuanto al análisis de sentimientos.

5.10. Estado del objeto de estudio

Mediante la aplicación de una revisión bibliográfica entorno a los temas de interés de la pregunta de investigación, se ha obtenido un conjunto de trabajos relacionados, los mismos que fundamentan el presente TT. El proceso de su obtención se detalla en el Anexo I.

El trabajo [25], realizó un estudio en el que mediante la herramienta Stanford NLP se analizan qué sentimientos reflejan los mensajes publicados hacia el Ex Presidente del Ecuador Rafael Correa y hacen un contraste con los resultados del candidato oficialista de las elecciones 2017. En concreto, determinaron que los sentimientos hacia el presidente no afectaron a ningún proceso electoral de su partido.

La plataforma para la recolección de los mensajes ha sido Twitter, en donde, de los 17818 tuits que corresponden a la precampaña, 8827 han sido clasificados como “negativos”, descalificando la gestión del Ex Presidente Rafael Correa; 4727 tuits fueron “neutrales” y 4264 se determinaron con sentimientos “positivos” evidenciando: amor, gratitud y respaldo hacia el ex presidente.

También recogieron una muestra de 5766 tuits durante la campaña electoral, dando los siguientes resultados: 2790 tuits de rechazo, 1641 neutrales y 1335 tuits con mensajes positivos hacia el ex presidente.

El estudio [26], demuestra el potencial que tiene realizar análisis de sentimientos en las redes sociales, a través del procesamiento del lenguaje natural y exponiendo sus ventajas en comparación a los métodos tradicionales existentes.

Demuestra que el modelo de Redes Neuronales a pesar de requerir abundante tiempo de procesamiento durante el entrenamiento, ha tenido el mejor desempeño durante la clasificación de los tuits recolectados y tratados previamente mediante un script de Python. Durante la evaluación además de Redes Neuronales se consideraron los modelos SVM, Naive Bayes y Random Forest.

El artículo [27], indica la realización de un estudio acerca de las posibles técnicas aplicables a la minería de opiniones, para la obtención de textos en redes sociales de un personaje público en Ecuador, para determinar la polaridad de sentimientos de los usuarios hacia dicho personaje, siendo posible una calificación de su gestión como neutra, positiva o negativa.

Dado el análisis de 71845 tuits, dio a conocer que en su mayoría un 92% las opiniones hacia el personaje son neutras, con un 3% de comentarios negativos y un 4% de opiniones positivas que al ser muy bajas no son nada favorables.

El trabajo [28], emplea una nueva forma o metodología de predicción electoral, se considera nueva ya que la fuente de análisis no toma relevante a los tuits recolectados, sino más bien a los electores, ya que estos influyen como persuasores para otros electores que no tienen un criterio completamente definido hacia cierto partido político; a través de la red social Twitter realizó la recolección de los tuits con sus respectivos autores. La predicción de esta nueva metodología se validó con el resultado real de las encuestas realizadas en Ecuador entre diciembre del 2016 a febrero del 2017.

Fueron obtenidos 823135 tuits correspondientes a los electores que seguían las cuentas oficiales de sus partidos políticos y mediante la construcción de un diccionario de palabras tanto positivas como negativas, de 1625 y 2942 respectivamente, utilizando el método de Enfoque Basado en Lexicones para adaptarse al español de Ecuador.

En la Tabla 5.2 se plasman los resultados de la predicción para cada uno de los candidatos con su respectiva polaridad de sentimiento.

Tabla 5.2: Polaridad según el candidato

Candidato	En contra	Neutro	A favor	Total
Lenin Moreno	2520	27611	10525	40656
Guillermo Lasso	2370	17031	8143	27544
Cynthia Viteri	1095	9926	3984	15005
Paco Moncayo	1134	12917	1649	15700
Otros	3368	26948	3157	33473
Total	10487	94433	27458	132378

Y a través de la Tabla 5.3 se presentan y comparan tanto los resultados de las encuestas (datos reales) como los datos resueltos por modelos predictivos.

Tabla 5.3: Comparación de los resultados oficiales con los datos predichos.

Candidato	CNE	Resultado de las empresas encuestadoras					Propuesta	
		MARKET	CIES	Perfiles de opinión	Opinión pública Ecuador	CEDATOS	Sin utilizar el factor de ponderación geográfico	Utilizando el factor de ponderación geográfico
Lenin Moreno	39,4	32,4	43,3	41,7	42,6	38,6	38,3	41,7
Guillermo Lasso	28,1	20,8	21,3	19,0	22,7	25,7	29,7	27,7
Cynthia Viteri	16,3	23,0	12,6	16,7	17,1	16,7	14,5	14,0
Paco Moncayo	6,7	13,1	10,8	8,3	9,2	9,2	6,0	6,6
Otros	9,5	10,7	12,0	14,3	8,5	9,7	11,5	10,1
Total	100	100	100	100	100	100	100	100
MAE			5,7	4,2	3,6	1,3	1,4	1,1

Como se puede evidenciar, se tiene un bajo porcentaje de error, los resultados de la propuesta son muy próximos a los datos reales.

El estudio [29], ha desarrollado un sitio web en el que permite descargar tuits a través de los servicios de Twitter, los que servirán como insumos para cualquier herramienta de análisis de sentimientos, con el propósito de extraer la polaridad de las opiniones expuestas por los usuarios de dicha red social acerca de cualquier tema en general.

Este trabajo llega a ser útil para cualquier persona que requiera conocer el comportamiento de los usuarios en la internet frente a alguna situación, como por ejemplo: al momento de elegir cierto producto, al determinar la satisfacción de los clientes consumidores de dicho producto e incluso predecir los resultados de futuras elecciones políticas, basándose en las opiniones difundidas en la redes sociales entorno a los candidatos.

La investigación [30], propone una serie técnicas para el análisis de sentimientos como son: bolsa de palabras, tokenización, derivación, la eliminación de signos y números, y un clasificador bayesiano; dichas técnicas las emplea para la detección de acoso

cibernético en la redes sociales de las publicaciones en español. Utiliza el Diccionario Español de Afectos en el Lenguaje (SDAL) como fuentes de las palabras afectivas categorizadas en: agradabilidad, activación (pasivo, activo) y facilidad de imaginar, cabe destacar que dicha categorización ya la ofrece el diccionario antes mencionado. Con el apoyo del diccionario se obtuvieron nuevas palabras entorno a la misma categorización, para cumplir dicha tarea han intervenido los miembros del Centro de Investigación, Transferencia de Tecnología y Desarrollo de Software (CiTeSoft). Finalmente, el software desarrollado ha ofrecido un éxito del 93% de efectividad para la detección del acoso en redes sociales, esto es, de acuerdo a los resultados de las pruebas de validación realizadas.

La investigación [31], determina que existe una escasez de recursos en español para el análisis de sentimientos u opiniones, por esta razón proponen la creación de MOAS-Les, esta es una herramienta que permite expresar la polaridad de textos en idioma español, cumple con esta tarea considerando la orientación semántica, el procesamiento de los intensificadores, atenuadores y oraciones adversativas; esto ayuda enormemente a los investigaciones que su momento requieran de una herramienta en dicho idioma.

Con una muestra de 1000 textos fue evaluado el rendimiento de esta herramienta que utiliza clasificación no supervisada, es decir, se omite la fase de entrenamiento; los resultados de clasificación de polaridad fueron satisfactorios para MOAS-Les con respecto a otros sistemas netamente léxicos o sintácticos.

El estudio [32], ha desarrollado un sistema que utiliza el análisis de sentimientos para recabar las características positivas o negativas de un establecimiento turístico, utilizando Big Data para el almacenamiento y gestión de los datos iniciales. El diseño del sistema está dividido en 3 bloques:

- Extracción, donde se recogen los datos y se adaptan para los siguientes bloques.
- Análisis, donde se realiza el núcleo central del proyecto y se obtienen resultados.
- Representación, donde se sintetizan e interpretan los resultados.

Los procesos más destacables del proyecto son:

La agrupación de las Keywords, que definan al mismo elemento en una única Colección de Sentimientos, creando nuevas colecciones en caso de encontrar nuevas Keywords.

Analizar las Keywords mediante un método de análisis por diccionario para retirar adjetivos y otros elementos que impidan una agrupación apropiada de las Keywords, en caso de que encuentre que la Keyword en particular sea un término compuesto y no

una sola palabra.

Uno de los puntos desfavorables es que el análisis de diccionario utilizado en este estudio, solo trabajar en el lenguaje inglés, pero tiene ciertas ventajas ya que, tras analizar el texto, le agrega etiquetas (“tags”) en función de si es un sustantivo, un adjetivo, un verbo.

Una vez generadas todas las colecciones de sentimientos, se calcula el número de opiniones negativas, positivas y neutras, y almacena los resultados en la colección correspondiente.

Finalmente, el archivo DATA que contiene todas las colecciones de sentimientos está organizado por el nombre de los elementos y el atributo Cantidad de dichos objetos, primando este último criterio.

El estudio [33], pretende definir un método para determinar los sentimientos que los problemas declarados en los tickets para soporte Tecnologías de la Información (TI) puedan contener, estos tickets puede crearse a partir de problemas como: de infraestructura, infecciones, errores, incidentes, solicitudes, etc. Determinó un primer desafío al momento de diferenciar automáticamente entre información fáctica (negativa) de aquel sentimiento encontrado en la descripción.

Esto lo supera con la creación automática de un diccionario de dominio en que se encuentran todas las palabras clasificadas de acuerdo a los sentimientos en el contexto de la Tecnología de la Información.

La investigación [34], tiene como objetivo analizar los diversos métodos y algoritmos existentes para tratar los textos, en este caso, específicamente de tuits. Expresa un modelo para realizar de forma automática la clasificación de tuits, con el propósito de comprender las intenciones de un usuario al momento de hacer público un tuit. Para esto, determinan ocho categorías, las mismas que utilizan algoritmos de clasificación supervisada, como son: Super Vector Machine (SVM) y Naive Bayes; posterior a la ejecución y evaluación de los algoritmos, determinó que el SVM mantiene un rendimiento y exactitud superior para cumplir con la tarea objetivo, es decir, para la clasificación automática de los tuits.

La investigación [35], fundamenta de manera teórica y práctica las principales técnicas de minería de datos e inteligencia artificial, aplicados a procesamiento y análisis de los textos encontrados en las redes sociales. Entre estos algoritmos, los que más se destacan son: Análisis de Asociaciones, Agrupamiento, Clasificación y Predicción.

Así mismo, realiza dos tareas prácticas, estas son: para el sondeo de redes sociales

mediante el análisis de sentimientos de los usuarios en relación a algún tema en particular y también para la búsqueda de clientes potenciales, es decir, muestren interés sobre cierto tema o producto.

El estudio [36], identifica los tuits que divulgan discursos del odio, en el que participan las cuentas en Twitter de actores políticos, los medios de comunicación y sus presentadores, siendo estos uno de los que pueden fomentar a que los ciudadanos lo repliquen; toman como referencia a la teoría de la agenda building y sus esferas: política, mediática y pública.

Mediante la exploración les permite comprobar cuál de las tres esferas generan un mayor discurso de odio que van contra los inmigrantes centroamericanos en México. Cabe destacar que hoy en día dichas prácticas de discursos de odio, se han propagado rápidamente por las redes sociales y su nivel de difusión es enorme.

La investigación [37], manifiesta que en la red social Facebook, fueron examinadas 100 páginas, considerando sus mensajes y comentarios, en lo que se descubrieron 494 situaciones en la que se incentiva al odio en la red, en lo que eran afectadas directamente las comunidades musulmanas.

Los resultados revelaron alguno paralelismos interesantes y características comunes compartidas dentro de estos grupos, lo que ayudó al autor a crear una tipología de cinco características de odio contra los musulmanes propugnada en Facebook. En general, este estudio encontró musulmanes siendo demonizados y vilipendiados en línea que se había manifestado a través de las actitudes negativas, la discriminación, los estereotipos las amenazas físicas y acoso en línea que todos tenían el potencial para la violencia o incitan la acción perjudicial, ya que desprecia e intimida a un individuo o grupo protegido. que ayudó al autor a crear una tipología de cinco características de odio contra los musulmanes propugnada en Facebook.

El estudio [38], destaca que al detectar a tiempo los diferentes tipos de actitudes tanto violentas o peligrosas en las redes sociales se puede llegar a prevenir sus efectos que generalmente llegarían a ser negativos. Es por eso que se trata de resolver el tema de seguridad, específicamente las actitudes sospechosas hacia la violencia de género o bullying. De manera concreta pretenden realizar y ofrecer un modelo que conlleve al análisis y extracción de información como mensajes u opiniones públicas que se encuentran en las redes sociales, para demostrar con diversos métodos de aprendizaje, entre estos se destacan: la minería de datos y análisis de sentimientos, permitiendo detectar a tiempo al autor de mensajes u opiniones que llegan a ser violentos o peligrosos.

El estudio [39], indica que uno de los acontecimientos que ocasionó gran conmoción en las redes sociales fue el atentado en las instalaciones del semanario Charlie Hebdo

en París, permitiendo la aplicación de métodos de recolección de datos para estos mensajes violentos en la red social Twitter, en la que se consiguió crear una colección de 282397 tuits, dando cabida al análisis de los mismos, a través de enfoques cualitativos y cuantitativos permitiendo dar un contraste a los resultados entre cada uno de los métodos empleados. Dichos resultados se obtuvieron mediante una muestra de 2304 tuits, así mismo, se categorizó cada uno de los tuits de acuerdo al tipo de sentimiento, estos se presentan en la Tabla 5.4.

Tabla 5.4: Categorización de los sentimientos del atentado en París

Categoría/Sentimiento	Cantidad	Porcentaje
Incitación a la violencia	135	5,87%
Ofensa personal	114	4,96%
Incitación a la discriminación	984	42,61%
Ofensa colectiva	1071	46,57%
Total	2304	100%

El estudio [40], presenta una herramienta integral de análisis de sentimientos en redes sociales. La cual es una aplicación web que interactúa con Twitter y está dirigida a una amplia gama de usuarios, ya que puede ser utilizada tanto como una actividad recreativa y de disfrute, como así también para analizar la respuesta en las redes sociales a un producto o servicio de determinada empresa o entidad.

5.10.1. Conclusión

De acuerdo al análisis de cada uno de los trabajos relacionados al objeto de estudio, se ha encontrado que mediante la inteligencia artificial y a través de técnicas de procesamiento de lenguaje natural, se posibilita analizar los sentimientos presentes en datos textuales, como pueden ser en: tuits, opiniones de sitios turísticos, sugerencias acerca de un servicio, etc. Entre los lenguajes y herramientas mayormente utilizadas está R que a través de librerías permite aplicar técnicas de análisis de sentimientos como son: bolsa de palabras, tokenización, derivación, la eliminación de signos y números, eliminación de stopwords..., etc. y Stanford NLP que así mismo permite la realización de diferentes fases para el análisis de sentimientos, desde el tratamiento de los textos hasta su representación.

También se han empleado algunos diccionarios que facilitan el tratamiento de la información, ya que permiten agregar etiquetas (“tags”) a cada palabra analizada, en función de si es un sustantivo, adjetivo o verbo.

El conocimiento de estas técnicas y herramientas para el PLN y análisis de sentimientos mediante su correcta aplicación permitirán una adecuada realización del presente TT.

6. Metodología

En el presente TT se emplea el tipo de investigación tecnológica y el nivel de investigación aplicada, con el propósito de descubrir la existencia de tuits con contenido xenófobo a inmigrantes venezolanos, esto se lleva a cabo utilizando los tuits como insumos para la obtención de información que brindarán elementos útiles para otros proyectos.

Así mismo, emplea el método de investigación sistémico, en donde, mediante la aplicación del procesamiento de lenguaje natural, analiza discursos del odio encontrados en los tuits recogidos previamente, con el fin de determinar la existencia de sentimientos xenófobos en los mismos.

6.1. Métodos

Los siguientes métodos están basados en cada uno de los objetivos específicos del presente TT.

6.1.1. Ejecutar revisión bibliográfica para el análisis de sentimientos en Twitter

6.1.1.1. Método de revisión bibliográfica

La revisión bibliográfica permite el análisis de información ya existente sobre un tema en particular de diferentes fuentes, como pueden ser: revistas, artículos científicos, libros, material archivado y otros trabajos académicos, su propósito es recopilar y analizar críticamente los documentos relacionados, para posteriormente permitir dar respuesta a la pregunta de investigación inicialmente propuesta.

El método a utilizar se basa en las fases de la metodología para Revisiones Sistemáticas de Literatura (RSL) de Bárbara Kitchenham, en el contexto de una revisión bibliográfica.

6.1.2. Aplicar metodología para el análisis de sentimientos

6.1.2.1. Minería de textos

Este método consiste en un proceso semiautomatizado para la extracción de información útil e identificación de patrones en grandes de datos textuales que suelen ser complejos, debido a su heterogeneidad y al no ser estructurados, en el que puede usarse algoritmos y técnicas para el análisis de dichos textos, así mismo, permite el análisis de opiniones o sentimientos para diferentes tipos de investigación, como puedes ser el presente TT.

6.1.3. Interpretar los resultados obtenidos en el análisis de sentimientos

6.1.3.1. Visualización de reglas de asociación para la minería de textos

Las reglas de asociación permiten encontrar relaciones de asociación o correlación entre un conjunto extenso de datos, en caso de la minería de textos se encuentran escritos en lenguaje natural en bases de datos textuales. A través de representaciones gráficas se muestran las frecuencias de las palabras, la polaridad los sentimientos, etc.

6.2. Técnicas

La siguiente técnica está basada de manera general en los objetivos del presente TT.

6.2.1. Técnica para minería de textos

Para llevar a cabo el procesamiento de los textos y por ende el análisis de sentimientos, se requiere emplear técnicas en que las que involucran diversos procesos como: recopilación de los textos, extracción de información de interés, procesamiento de lenguaje natural y minería de datos para el descubrimiento de la relación entre asociaciones y hechos que desconocemos.

Como ejemplo, se tiene la técnica KDT en la que de manera resumida se puede presentar en tres etapas: preprocesamiento (extracción de tuits, lematización, categorización, ...), minería de textos (algoritmos de análisis de sentimientos, ...) y visualización de resultados (interpretación de resultados con respecto a lo esperado...). Cabe destacar que dicha técnica o metodología aún se debe definir, de acuerdo a lo estipulado en el alcance del presente TT.

7. Cronograma

Tabla 7.1: Cronograma de actividades

Actividades	Semanas																			
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
Realizar una revisión bibliográfica acerca del análisis de sentimientos en Twitter	■	■	■	■	■	■	■													
Realizar revisión bibliográfica basada en las fases de la metodología de RSL de Bárbara Kitchenham	■	■	■	■																
Determinar metodología para el análisis de sentimientos					■	■	■													
<i>Identificar el lenguaje de programación, algoritmos, herramientas y software en general necesario para realizar cada una de las fases de la metodología de análisis de sentimientos</i>						■	■													
Aplicar metodología para el análisis de sentimientos								■	■	■	■	■	■	■	■					
Identificar el intervalo de tiempo más conveniente para delimitar la búsqueda y extracción de los tuits								■	■											
Ejecutar las fases de la metodología seleccionada										■	■	■	■	■	■					
Interpretar los resultados obtenidos en el análisis de sentimientos																■	■	■	■	■
Analizar e identificar los mejores algoritmos para el análisis de sentimientos																■	■			
Interpretar los resultados obtenidos																		■	■	
Dar contestación a la pregunta de investigación																				■

8. Presupuesto

Para la ejecución del presente TT, se requiere de algunos recursos, entre estos, el económico, por lo que se propone el siguiente presupuesto que está dado por algunas categorías, como son: Talento Humano (Tabla 8.1), Recursos Técnicos y Tecnológicos (Tabla 8.2) , Servicios (Tabla 8.3) y Recursos Materiales (Tabla 8.4).

Tabla 8.1: Presupuesto para Talento Humano

Talento Humano			
Responsable	Número de horas	Costo por hora	Costo total
Tesista	400	\$2.50	\$1,000.00
Director	40	\$10.48	\$419.00
Docente de TT	80	\$10.48	\$838.00
TOTAL			\$2,257.00

Tabla 8.2: Presupuesto para Recursos Técnicos y Tecnológicos

Recursos Técnicos y Tecnológicos			
Recursos de Software			
Nombre			Costo total
LibreOffice			\$0.00
Mendeley Desktop			\$0.00
Google Chrome			\$0.00
LaTeX			\$0.00
Herramienta recolectora de tuits			\$220.00
Lenguaje de programación para el PLN			\$0.00
Herramientas para el preprocesamiento, minería de textos y visualización			\$0.00
SUBTOTAL			\$220
Recursos de Hardware			
Nombre	Cantidad	Costo unitario	Costo total
Laptop	1	\$600.00	\$600.00
Impresora	1	\$240.00	\$240.00
SUBTOTAL			\$840.00
TOTAL			\$1,060.00

Tabla 8.3: Presupuesto para Servicios

Servicios			
Nombre	Meses	Costo unitario	Costo total
Internet	5	\$20.00	\$100.00
Transporte	5	\$12.00	\$60.00
TOTAL			\$160.00

Tabla 8.4: Presupuesto para Recursos Materiales

Recursos Materiales			
Nombre	Cantidad	Costo unitario	Costo total
Resma de papel bond	1	\$3.50	\$3.50
Tinta para impresiones	4	\$10	\$40.00
Empastados, anillados	2	\$8.00	\$16.00
CDs	3	\$1.75	\$5.25
TOTAL			\$58.75

En síntesis, para cada uno de los presupuestos dados, se presenta el Presupuesto General (Tabla 8.5), en donde se contempla la sumatoria total de los valores propuestos para cada una de las categorías de presupuestos, agregando un valor del 10% para gastos imprevistos; de manera particular se aclara que el presupuesto para talento humano se considera solo del tesista, dado que los gastos que demandan el director y el docente de TT los asume la institución para la cual trabajan, es decir, la Universidad Nacional de Loja.

Tabla 8.5: Presupuesto General

Presupuesto General	
Descripción	Costo total
Talento Humano	\$1,000.00
Recursos Técnicos y Tecnológicos	\$1,060.00
Servicios	\$160.00
Recursos Materiales	\$58,75
Imprevistos (10%)	\$277,88
TOTAL	\$2,506.63

Bibliografía

- [1] C. Mart, “An a Twitter : El bueno , el malo y el > :(,” 2016.
- [2] M. İlhan, “Trending Topic History,” *Trending Topic History*, 2016.
- [3] Statista, “Twitter: number of active users 2010-2019 | Statista,” 2019.
- [4] M. B. Valdez-Apolo, “El discurso del odio hacia migrantes y refugiados a través del tono y los marcos de los mensajes en Twitter,” vol. 6, pp. 361–384, 2019.
- [5] W. Swing, Lacy, *Organización Internacional para las Migraciones*. 2017.
- [6] M. Hopenhayn and Á. Bello, *Discriminación étnico-racial y xenofobia en América Latina y el Caribe*. No. 47, 2001.
- [7] ELTIEMPO, “Feminicidio en Ecuador genera xenofobia y control para venezolanos - Latinoamérica - Internacional.”
- [8] República del Ecuador, “Codigo Organico Integral Penal,” *Noticias*, p. 1, 2018. [9] E. Ibarra, *La España racista: la lucha en defensa de las víctimas del odio*. 2011. [10] M. S. V. Martínez and M. Á. Cea D’Ancona, *Evolución del racismo y la xenofobia en España*, vol. 0. 2010.
- [11] M. S. Brugués and J. D. Nicolás, *Las dos caras de la inmigración*. No. 116, 2006.
- [12] Naciones Unidas, *La Agenda 2030 y los Objetivos de Desarrollo Sostenible: una oportunidad para América Latina y el Caribe. LC/G.2681-P/Rev.3*, Santiago. 2018.
- [13] MINTEL and SENESCYT, “Líneas de investigación, desarrollo e innovación y transferencia del conocimiento en TIC 2019,” *Mintel*, p. 110, 2019.
- [14] SENESCYT, “Bases para la convocatoria para el financiamiento de proyectos de fomento a la investigación y/o desarrollo tecnológico a través de fondos concursales, dirigida a los actores generadores y gestores del conocimiento del Sistema Nacional de Ciencia, Tecnolo,” 2018.
- [15] Universidad Nacional de Loja(UNL), “Investigación | Universidad Nacional de Loja,” 2014.

-
- [16] Ajuntament de Barcelona, “Contróláte en las Redes! #BCNvsODI,” 2017.
- [17] L. Bustos Martínez, P. P. De Santiago Ortega,, M. Á. Martínez Miró, and M. S. Rengifo Hidalgo, “Discursos de odio: una epidemia que se propaga en la red. Estado de la cuestión sobre el racismo y la xenofobia en las redes sociales,” *Mediaciones Sociales*, vol. 18, pp. 25–42, may 2019.
- [18] J. M. León, “La xenofobia en Ecuador empuja a migrantes venezolanos a salir del país,” 2019.
- [19] E. A. Doctor and J. L. Pino, “Técnicas Estadísticas en Minería de Textos,” 2018.
- [20] G. Mariscal, Ó. Marbán, and C. Fernández, “A survey of data mining and knowledge discovery process models and methodologies,” *Knowledge Engineering Review*, vol. 25, no. 2, pp. 137–166, 2010.
- [21] M. C. Justicia de la Torre, *Nuevas Técnicas De Minería De Textos: Aplicaciones*. 2017.
- [22] K. Bock and S. M. Garnsey, “Language Processing,” *A Companion to Cognitive Science*, pp. 226–234, 2015.
- [23] R. F. Medina-Merino and C. I. Ñique-Chacón, “Bosques aleatorios como extensión de los árboles de clasificación con los programas R y Python,” *Interfases*, vol. 0, no. 010, p. 165, 2017.
- [24] R. Jongeling, P. Sarkar, S. Datta, and A. Serebrenik, “On negative results when using sentiment analysis tools for software engineering research,” *Empirical Software Engineering*, vol. 22, no. 5, pp. 2543–2584, 2017.
- [25] O. Hidalgo, R. Jaimes, E. Gomez, and S. Lujan-Mora, “Sentiment analysis applied to the popularity level of the ecuadorian political leader Rafael Correa,” *Proceedings - 2017 International Conference on Information Systems and Computer Science, INCISCOS 2017*, vol. 2017-Novem, pp. 340–346, 2018.
- [26] P. D. Leonardo, “Análisis de sentimientos. Aplicación sobre textos en redes sociales,” 2019.
- [27] B. Herrera Flores, “Polaridad de las opiniones sobre un personaje público en el Ecuador Polarity of opinions about a public person in,” vol. V, no. 2, pp. 27–32, 2018.
- [28] J. A. Rimassa, “El análisis de opiniones en la predicción política basados en Twitter. Un nuevo enfoque.,” p. 102, 2019.
- [29] D. Rubio Cortés, “Herramienta para el análisis de opiniones y sentimientos sobre Twitter,” 2017.
-

-
- [30] R. N. Montufar Mercado, “Automatic Cyberbullying detection in Spanish-Language Social Networks using Sentiment Analysis Techniques,” 2019.
- [31] J. A. López-Palma and M. Estévez-Crespo, “MOAS-Les, herramienta para el análisis de sentimientos de textos en idioma español,” pp. 1–20, 2016.
- [32] N. Marín Siruela, “Extractor y comparador de características para establecimientos turísticos empleando análisis de sentimientos con Big Data,” 2017.
- [33] J. N. Briones, “Análisis de sentimientos en sistemas de ticketing IT,” 2019.
- [34] L. Y. Segura Vásquez, “Evaluación de Algoritmos de Clasificación para el Minado de Opinión en Twitter,” 2019.
- [35] L. Piñón Ferrer, “Minería de datos aplicada a Twitter y análisis de sentimientos mediante algoritmos de inteligencia artificial,” 2018.
- [36] C. Edmundo and A. Calderón, “El discurso del odio contra los inmigrantes centroamericanos en México : Análisis de la xenofobia y el racismo en políticos , medios y ciudadanos,” pp. 1–7, 2019.
- [37] I. Awan, “Islamophobia on social media: A qualitative analysis of the facebook’s walls of hate,” *International Journal of Cyber Criminology*, vol. 10, no. 1, pp. 1–20, 2016.
- [38] J. Calloni, P. Paez, J. Saldarini, J. Cuevas, M. Mulassano, A. Bianciotti, E. Scarello, L. Banchio, F. Degiovanni, and L. Scharff, “Modelo para Analizar Mensajes y Detectar Actitudes Peligrosas a través de Análisis de Sentimientos con Algoritmos de Aprendizajes,” *XIX Workshop de Investigadores en Ciencias de la Computación*, pp. 100–104, 2017.
- [39] F. Miro-Llinares and J. J. Rodríguez-Sala, “Cyber hate speech on twitter: Analyzing disruptive events from social media to build a violent communication and hate speech taxonomy,” *International Journal of Design and Nature and Ecodynamics*, vol. 11, no. 3, pp. 406–415, 2016.
- [40] P. E. Rom and M. G. Armentano, “Herramienta integral de análisis de sentimientos en Agradecimientos,” 2018.
- [41] M. Petticrew and H. Roberts, *Systematic Reviews in the Social Sciences*. 2006.
- [42] M. Bruzza, A. Cabrera, and M. Tupia, “Survey of the state of art based on PICO about the use of artificial intelligence tools and expert systems to manage and generate tourist packages,” *2017 International Conference on Infocom Technologies and Unmanned Systems: Trends and Future Directions, ICTUS 2017*, vol. 2018-Janua, pp. 290–296, 2018.
-

-
- [43] D. Yang, A. N. Zhang, and W. Yan, “Performing literature review using text mining, Part I: Retrieving technology infrastructure using Google Scholar and APIs,” *Proceedings - 2017 IEEE International Conference on Big Data, Big Data 2017*, vol. 2018-Janua, pp. 3290–3296, 2017.

Lista de Acrónimos y Abreviaturas

ACNUR	Alto Comisionado de las Naciones Unidas para los Refugiados.
CEDHU	Comisión Ecuamélica de los Derechos Humanos.
CiTeSoft	Centro de Investigación, Transferencia de Tecnología y Desarrollo de Software.
COIP	Código Orgánico Integral Penal.
CRISP-DM	Procesos Estándar para la Minería de Datos.
KDD	Descubrimiento de Conocimiento en Bases de Datos.
KDT	Descubrimiento de Conocimiento en Textos.
NLTK	Natural Language Toolkit.
ODS	Objetivo de Desarrollo Sostenible.
ONU	Organización de las Naciones Unidas.
PLN	Procesamiento del Lenguaje Natural.
RSL	Revisión Sistemática de Literatura.
SDAL	Diccionario Español de Afectos en el Lenguaje.
SENESCYT	Secretaría de Educación Superior, Ciencia, Tecnología e Innovación.
SVM	Super Vector Machine.
TI	Tecnologías de la Información.
TR	Trabajos Relacionados.
TT	Trabajo de Titulación.
UNL	Universidad Nacional de Loja.

A. Anexo I

A.1. Revisión Bibliográfica

A.1.1. Diseño

Se ha realizado una revisión sistemática de documentos para el análisis de sentimientos en Twitter. Para su realización se ha tomado como referencia las fases de la metodología para RSL de Bárbara Kitchenham, en el contexto de una revisión bibliográfica.

A.1.2. Estrategia de búsqueda

Según Petticrew y Roberts [41], a través de la nemotécnica PICOC, se estructuran los cinco componentes para definir la cadena de búsqueda, de los cuales en el presente TT no se considera el criterio de Comparación [42], por lo tanto, se emplearon solo cuatro componentes: Population (P), Intervention (I), Outcomes (O) y Context (C). Obteniendo la siguiente cadena de búsqueda:

("hate speech" OR "social networks" OR "twitter" OR "xenophobia") AND ("libraries" OR "methodologies" OR "methods" OR "software" OR "techniques" OR "tools") AND ("natural language processing" OR "sentiment analysis")

utilizada en inglés y su traducción en español:

("discurso de odio" OR "redes sociales" OR "twitter" OR "xenofobia") AND ("librerías" OR "metodologías" OR "métodos" OR "software" OR "técnicas" OR "herramientas") AND ("lenguaje de procesamiento natural" OR "análisis de sentimientos")

Aplicadas en las siguientes bibliotecas virtuales: IEEE Digital Library, Science@Direct, Springer Link y ACM Digital Library. Así mismo, se considera como indexador de contenido a Google Scholar, que según Zhang [43], ofrece la mayor cobertura de literatura científica y académica, pero, advierte que se debe utilizar con cuidado ya que también incluye sitios web en las que no realizan un control de calidad de sus trabajos científicos, es el caso de ResearchGate, donde sus usuarios pueden subir contenido sin una rigurosa revisión por pares.

A.1.3. Criterios de inclusión y exclusión

A.1.3.1. Criterio de inclusión

Fecha de publicación: se consideran los documentos desde el 2016 hasta el presente año.

A.1.4. Extracción de datos

Para una mejor organización y selección de todos los resultados, se ha utilizado la herramienta en línea Parsifal, la cual ayuda en el contexto de la Ingeniería del Software a realizar revisiones sistemáticas de literatura. Se han recogido los 483 resultados más relevantes entorno a las cadenas de búsqueda dadas anteriormente, de los cuales en la Tabla A.1 se presentan los Trabajos Relacionados (TR) más relevantes.

A.1.5. Análisis de los datos

Se ha realizado un análisis individual para cada uno de los trabajos relacionados propuestos, los mismos que aportaron con información relevante entorno a la pregunta de investigación definida en el presente TT, dicho análisis se redacta en la sección de Marco Teórico en el apartado de Estado del objeto de estudio.

Tabla A.1: Trabajos relacionados

Código	Título	Referencia
TR01	Sentiment analysis applied to the popularity level of the ecuadorian political leader Rafael Correa.	[24]
TR02	Análisis de sentimientos. Aplicación sobre textos en redes sociales.	[25]
TR03	Polaridad de las opiniones sobre un personaje público en el Ecuador	[26]
TR04	El análisis de opiniones en la predicción política basados en Twitter. Un nuevo enfoque.	[27]
TR05	Herramienta para el análisis de opiniones y sentimientos sobre Twitter.	[28]
TR06	Automatic Cyberbullying detection in Spanish-Language Social Networks using Sentiment Analysis Techniques.	[29]
TR07	MOAS-Les, herramienta para el análisis de sentimientos de textos en idioma español.	[30]
TR08	Extractor y comparador de características para establecimientos turísticos empleando análisis de sentimientos con Big Data.	[31]
TR09	Análisis de sentimientos en sistemas de ticketing IT.	[32]
TR10	Evaluación de Algoritmos de Clasificación para el Minado de Opinión en Twitter.	[33]
TR11	Minería de datos aplicada a Twitter y análisis de sentimientos mediante algoritmos de inteligencia artificial.	[34]
TR12	El discurso del odio contra los inmigrantes centroamericanos en México: Análisis de la xenofobia y el racismo en políticos, medios y ciudadanos.	[35]
TR13	Islamofobia en las redes sociales: un análisis cualitativo de las paredes de odio del Facebook.	[36]
TR14	Modelo para analizar mensajes y detectar actitudes peligrosas a través de análisis de sentimientos con algoritmos de aprendizajes.	[37]
TR15	Discurso de odio cibernético en Twitter: Analizando eventos disruptivos de medios sociales para construir una comunicación violenta y taxonomía de discurso odio.	[38]
TR16	Herramienta integral de análisis de sentimientos en Agradecimientos.	[39]

B. Anexo II

Entrevistas realizadas con el propósito de sustentar y justificar la realización del presente TT, tanto a nivel social como académico. Como apoyo de la información captada en las entrevistas, se adjunta las grabaciones de las mismas, en el siguiente enlace: <https://drive.google.com/open?id=1gNqSMraM3y-aaevO4w7Cbps1MeIJdNKW>. A continuación, se redacta fielmente las respuestas vertidas por sus autores.

B.1. Entrevista 1

Cargo: Especialista de la Unidad de Bienestar Universitario en el Área de Psicología de la UNL

Nombre: Dr. Paúl Palacios

Fecha: 03/03/2020

Descripción:

1. **¿Considera a la xenofobia como un problema social?**

Yo considero que la xenofobia es un problema muy grave, en virtud de que la gente por diferentes patrones culturales, genera a través de ese comportamiento xenofóbico animadversión, segregación e inclusive violencia contra determinadas personas por ser de alguna otra religión, de otro pensamiento político, filosófico e inclusive de nacionalidad.

2. **¿Qué opinión tiene usted acerca de la xenofobia hacia los inmigrantes venezolanos en Ecuador?**

Bueno es un hecho sumamente grave, la mayor parte de la gente ecuatoriana ha creado un factor psicológico de animadversión hacia los venezolanos por situaciones de diferente índole, especialmente por los que se dan por medios de comunicación, que no hay una información adecuada, muchos de los venezolanos yo diría la mayor parte son gente honesta, gente buena, pero hay quién que a través de campañas publicitarias especialmente por internet, se ha generado factores, haciendo creer que son personas malas, que son delincuentes, que no trabajan y eso genera la xenofobia, lleva a que se los excluya de la educación, de la salud, de los derechos fundamentales que tiene un ser humano.

3. **¿Considera que las redes sociales en el Ecuador influyen en la propagación de mensajes xenófobos?**

Yo creo que sí, las redes sociales son las que generan... yo diría la mayor parte de la xenofobia, porque existe mucha información que no es real, que no es verídica y, por lo tanto, como el mundo ahora pasa conectado con las redes sociales, esto se convierte en un patrón cultural, que hace que la xenofobia hacia ellos sea muy violenta e inclusive se ha llegado a agredirlos de una manera yo diría inhumana.

4. **Realizar un estudio en la red social Twitter para conocer la existencia de mensajes xenófobos hacia los migrantes venezolanos ¿le aportaría de alguna manera?**

Yo creo que sí, sería bueno estudiar ese comportamiento a través de Twitter y de las diferentes redes sociales para poder trazar una propuesta que permita que la gente cambie de actitud, porque es un problema de actitud, esa actitud de xenofobia genera muchos problemas, no solamente a nosotros sino fundamentalmente a ellos que necesitan vivir de forma digna, no es correcto que muchos de ellos por la xenofobia tengan que estar sin empleo, sin educación, sin trabajo y en condiciones sumamente precarias, tirados en las calles, niños abandonados; entonces yo creo que se puede hacer bastante a través de Twitter para que la gente cambie de actitud y romper esa xenofobia que hasta ahora es muy violenta.

B.2. Entrevista 2

Cargo: Gestora de la Carrera de Trabajo Social de la UNL

Nombre: Ing. Celia Jara Galdeman

Fecha: 03/03/2020

Descripción

1. **¿Considera a la xenofobia como un problema social?**

Sí, históricamente la xenofobia ha generado muchos conflictos entre países, entre personas, incluso ha llegado al extremo básicamente de generar hasta la muerte, entonces sí es considerado un problema social.

2. **¿Qué opinión tiene usted acerca de la xenofobia hacia los inmigrantes venezolanos en Ecuador?**

Es un sentimiento, una expresión, una posición que de alguna manera denota racismo, denota la no aceptación de otras personas que tienen nacionalidades diferentes a las nuestras o incluso en nuestro medio, personas que vienen de otros lugares o sectores, no es una buena posición porque esto nos genera de alguna manera vulneración de derechos y esa vulneración de derechos afecta a las personas, por ejemplo, el no darle un trabajo, no acceder a los servicios, por ejemplo, como salud, como educación, por el hecho de no ser ciudadanos de cierto sector, de cierta ciudad.

3. **¿Considera que las redes sociales en el Ecuador influyen en la propagación de mensajes xenófobos?**

Por supuesto, las redes sociales son medios de difusión sean de buenos o de malos mensajes, en este caso si alguien emite un mensaje con estas características de alguna manera está propiciando, motivando a que otros también lo hagan y ahí se puede generar un conflicto.

4. **Realizar un estudio en la red social Twitter para conocer la existencia de mensajes xenófobos hacia los migrantes venezolanos ¿le aportaría de alguna manera?**

Por supuesto, realmente esto sería una información muy importante, especialmente para las universidades, una fuente de información para poder proponer alternativas de solución, de hecho, conoceríamos en este caso el origen de las personas, de cuáles son las expresiones y sobre eso, actuar con las propuestas.

El respaldo formal de las entrevistas realizadas se especifican en la siguiente página adjunta.



1859

UNIVERSIDAD NACIONAL DE LOJA

Facultad de Energía, Industrias y Recursos Naturales no Renovables

Carrera de Ingeniería en Sistemas

Entrevista realizada por: Raúl Ramiro Romero Vega

Nombre	Institución/Empresa	Firma
Raúl Balseiro S.	U. N. L (U.R. U)	
Celia Jairo Galdames	U. N. L (Trabajo Social)	