



BENEMÉRITA UNIVERSIDAD AUTÓNOMA DE PUEBLA

COMPLEJO REGIONAL CENTRO - SAN JOSÉ CHIAPA

**Detección de Sarcasmo en Twitter a través de Algoritmos
de Minería de Datos para Conocer la Percepción sobre el
COVID-19**

T E S I S

Que para obtener el título de

**Licenciatura en Ingeniería en Sistemas y Tecnologías
de Información Industrial**

P R E S E N T A

Nombre Adriana Hernández Guerrero

ASESORES DE TESIS

Dra. María Claudia Denicia Carral
C. Dra. Ana Luisa Ballinas Hernández

Puebla, Pue., Junio 2021

Agradecimientos

A Dios por darme fuerza y sabiduría para poder culminar este trabajo de investigación.

A Dra. María Claudia Denicia Carral y C. Dra. Ana Luisa Ballinas Hernández por su apoyo guía y formación además de la disciplina y enseñanza. Gracias por la confianza y que hayan formado parte de este trabajo.

A los miembros del jurado la Mtra. Beatriz Alejandra Flores Rojas, Mtra. Irianely Ivonne Pérez Juárez y Dra. María Claudia Denicia Carral por tomarse el tiempo de leer y hacer las observaciones correspondientes del presente trabajo de tesis.

A mi apreciada Benemérita Universidad Autónoma de Puebla quien brindo las herramientas e información que aportaron a mi tema de investigación.

A mis padres José Doroteo Hernández Sánchez y Georgina Guerrero Varela por apoyarme y guiarme en el camino y siempre cuidar de mí.

A mi novio Jesús José Guadalupe Romero Camacho por ser mi inspiración de cada día, por su cariño por haber compartido sus recursos, por haber cuidado de mí. Gracias por la enseñanza y motivación.

Sin el apoyo de cada uno de ustedes esto no habría sido posible, a todos muchas gracias.

Resumen

El sarcasmo verbal es un fenómeno lingüístico muy difícil de detectar en el idioma español en México por la gran variedad de palabras que existen. Este trabajo tiene como objetivo detectar sarcasmo en textos cortos sobre un conjunto de tuits en español extraídos de Twitter para identificar la percepción de los usuarios con respecto a la COVID-19 pandemia que actualmente se afronta. Para la recolección de tuits que forman el corpus se usan dos APIs de la plataforma Twitter Developer: Search Tweets y Stream Tweets in real-time, así como el lenguaje Python en conjunto se realiza la extracción de los datos. Se aplican técnicas de minería de datos, en particular algoritmos de clasificación automática, para determinar si un texto es o no sarcástico. Se realizan dos experimentos con distintos corpus y cada uno se prueba con cuatro algoritmos de clasificación: Random forest, Naive Bayes, J48 y LibSV. Finalmente, se calcula la medida F- measure para determinar el algoritmo y el corpus que presenta mejores resultados. Se determinó que los algoritmos con mejores resultados para detectar sarcasmo a partir de hashtags de tuits tienen una precisión de la métrica F-measure Random forest con 0.864 y J48 con 0.864.

Palabras clave: Minería de Datos, Detección de Sarcasmo, Tuits, Minería de Textos, Twitter.

Contenido

Lista de Figuras	VI
Lista de Tablas.....	VII
1 Introducción	1
1.1 Planteamiento del problema	1
1.1 Objetivos	3
1.2 Pregunta de investigación	4
1.3 Justificación.....	4
1.4 Alcances y limitaciones.....	5
1.5 Organización de la tesis	6
2 Estado del arte	7
2.1 Redes sociales.....	7
2.2 Twitter.....	9
2.3 Detección de sarcasmo	10
2.4 Detección de sarcasmo cyberbullying en Twitter.....	11
2.5 Síntesis	18
3 Marco Teórico	19
3.1 Modelo KDD.....	19
3.2 Recolección y limpieza	22
3.3 Minería de datos	26
3.4 Evaluación de los modelos de clasificación	35
3.5 Sarcasmo.....	37
3.5.1 Tipos de sarcasmo	37

3.5.2	Sarcasmo Digital	38
3.6	API de desarrollo	39
3.7	Hashtag	41
3.8	Herramientas	42
3.9	Síntesis	43
4	Marco Metodológico	44
4.1	Caso de estudio	44
4.2	Metodología	45
4.2.1	Recolección de datos	45
4.2.2	Pre procesamiento	49
4.2.3	Selección de datos del tuit	49
4.2.4	Limpieza de datos	51
4.2.5	Transformación	54
4.2.6	Detección de sarcasmo y evaluación	55
4.2.7	Experimento 1	55
4.2.8	Experimento 2	57
4.3	Análisis de resultados	59
4.4	Síntesis	61
5	Conclusiones y trabajo a futuro	62
5.1	Conclusiones	62
5.2	Trabajo a futuro	63
6	Anexo	65
7	Bibliografía	67

Lista de Figuras

Figura 2-1. Grafica de Usuarios de Internet en México 2006-2018. Imagen obtenida de (Asociación de internet MX, 2021, pág. 4).	7
Figura 2-2. Actividades en línea. Imagen obtenida (Asociación de internet MX, 2021, pág. 13).	8
Figura 2-3. Redes sociales utilizadas. Imagen obtenida de (Asociación de internet MX, 2021, pág. 20).	9
Figura 3-1. Etapas del KDD (García-González, Sánchez-Sánchez, Orozco, & Obredor, 2019).	20
Figura 3-2 Anatomía de un tuit hacia el usuario. (DigitalTroupe Brand Services, 2015).	24
Figura 3-3. Un clasificador bayesiano ingenuo representado como una red bayesiana en la que los atributos predictivos (X_1, X_2, \dots, X_k) son condicionalmente independientes dado el atributo de clase (C) (H. John & Langley, 1995).	29
Figura 3-4. Predicción con Random Forest (Amat Rodrigo, Arboles de decision, Random Forest, Gradient Boosting y C5.0, 2015).	31
Figura 3-5. Hiperplano de separación (Amat Rodrigo, Cienciadedatos, 2015).	35
Figura 4-1. Pasos metodológicos para la detección de sarcasmo en tuits.	45
Figura 4-2. Código Python empleado para la conexión con Twitter.	46
Figura 4-3. Atributos de tuits separados.	50
Figura 4-4. Atributos de tuits separados.	51
Figura 4-5. Separación de menciones de los tuits.	52
Figura 4-6. Matriz de hashtags.	54
Figura 4-7. Nube de palabras.	60
Figura 4-8. Hashtags repetidos.	61
Figura 6-1. Código de conexión.	65
Figura 6-2. Código de conexión.	66

Lista de Tablas

Tabla 2-1. Trabajos relacionados al proyecto de investigación de detección de acoso o ciberbullying en tuits.	13
Tabla 2-2. Trabajos relacionados con el proyecto de investigación detección de sarcasmo o ironía en tuits.	16
Tabla 3-1 Partes de un tuit internamente (DigitalTroupe Brand Services, 2015).	25
Tabla 3-2. Herramientas usadas para el estudio de este proyecto.	43
Tabla 4-1. Recolección de tuits de acuerdo con las palabras usadas.	47
Tabla 4-2. Conexión a Mongo DB.	48
Tabla 4-3. Recolección de tuits usando dos modos de recolección y distintas APIs.	48
Tabla 4-4. Variables de un tuit (Twitter, 2019).	49
Tabla 4-5. Tuits procesados.	55
Tabla 4-6. Experimento 1 variando las columnas de la matriz.	56
Tabla 4-7. Resultados de F-Measure usando Naive Bayes para el experimento	56
Tabla 4-8. Resultados de F-Measure usando Naive Bayes para el experimento 1.	57
Tabla 4-9. Experimento 2 a partir de segundo corpus y solo con hashtags.	58
Tabla 4-10. Resultados de F-Measure usando diferentes modelos para el experimento 2.	58
Tabla 4-11. Resultados F-Measure usando diferentes modelos para el experimento2.	59

Capítulo 1

1 Introducción

El sarcasmo verbal es fenómeno lingüístico difícil de detectar en el idioma español de México por la gran variedad de palabras y significados que existen. Existen trabajos relacionados con la detección de sarcasmo en textos, pero la mayoría funcionan para otros idiomas y utilizan diversas técnicas algunos optaron por clasificadores de minería de datos, aprendizaje automático y/o aprendizaje profundo, analizadores emocionales, diccionarios léxicos etc. En el idioma español existen algunos que son enfocados a la ironía un tema completamente diferente o a solo detectar palabras ofensivas un tema que para México además de tener muchas palabras, en el ámbito de identificar malas palabras no deja de ser un tema complejo, todos los trabajos realizados que existen son sobre la red social Twitter, puesto que además de permitir hacer uso de los datos a desarrolladores también permite en otros tipos de usuarios como empresas lo que hace a Twitter una red social interesante para hacer análisis de su información.

1.1 Planteamiento del problema

Todas las personas que cuentan con un dispositivo móvil con Internet y más aún que hagan uso de la red social Twitter aumenta el hecho de que estén expuestos a leer mensajes y/o comentarios ofensivos al igual que hacer cualquier tipo de opinión ante algún tema. A partir de la pandemia incrementaron los usuarios, de acuerdo a (Asociación de internet MX, 2021) en el año 2020 México alcanza un 74% de

penetración entre la población de personas de 6 años en adelante con 87.4 millones de usuarios conectados a Internet.

Anudado a esto las redes social Twitter se coloca en la quinta posición con 57% en ser utilizada a diferencia de que en el 2019 el uso era del 39% lo que indica que el incrementó para el 2020 fue de un 18%. Además, las redes sociales en época de contingencia, significaron tiempo relevante para los internautas en México, 4 horas y 8 minutos de conexión diarios, 37 minutos más que en 2019 y no solo eso, si no que representa el 31% del tiempo invertido de conexión diario a Internet en México, además de que por primera vez la asociación de Internet midió los hábitos de las redes sociales y observaron que Twitter recuperó cierto terreno que había perdido en años previos (Asociación de internet MX, 2021).

A consecuencia del incremento de internet, usuarios y uso de las redes sociales como ya se mencionó la forma de socializar y expresarse a través de este medio siempre ha sido un tema complejo que se regule de manera oportuna casos de ciberbullying es por ello que los casos de ciberbullying en México van en aumento ante la poca legislación sobre el tema. En tal sentido en 2019 el 40.3% de las mujeres de 12 años y más víctima de ciberbullying recibió insinuaciones o propuesta sexuales. Por su parte, 33% de los hombres víctima de ciberbullying recibió mensajes ofensivos (INEGI, 2020).

Es necesario resaltar que en estudios que existen acerca de análisis de tuits para detectar ciberbullying, ironía y sarcasmo en el idioma inglés, sin embargo, no hay alguno dedicado al sarcasmo en español México, ya que es una forma indirecta de

insultar. El actual trabajo intenta identificar el sarcasmo y entender la forma de expresión de los usuarios en la red social Twitter durante el confinamiento por la pandemia de COVID-19.

1.1 Objetivos

Los objetivos que se persiguen en este trabajo de tesis son los siguientes:

Objetivo General

El objetivo general es detectar sarcasmo en textos cortos a partir del análisis de los componentes de un tuit para identificar la percepción de los usuarios con respecto a la enfermedad COVID-19.

Objetivos Específicos

- Recolectar los tuits en español de la plataforma Twitter Developer a través de la API de la plataforma.
- Realizar el procesamiento de datos a través de la identificación del texto y de su contexto para aplicar técnicas análisis lingüístico.
- Seleccionar los algoritmos de clasificación que mejor funcionan con los textos cortos.
- Evaluar y analizar los resultados de la clasificación del sarcasmo a través de métricas estandarizadas.

1.2 Pregunta de investigación

¿De qué manera impacta la pandemia del COVID-19 en los usuarios de la red social Twitter? Afecta a los usuarios emocionalmente provocando realizar o recibir comentarios sarcásticos sobre el tema del coronavirus ante la forma en que se está manejando dicha situación.

1.3 Justificación

El Internet ha tenido una evolución de manera muy acelerada, pues de tener pocos usuarios en sus inicios, actualmente, cuenta con millones de usuarios que pueden interactuar de manera activa a través de redes sociales. Sin embargo, esta interacción al ser libre y sin una regulación de por medio, propicia tanto ventajas como desventajas, entre las principales ventajas están obtener información de forma ágil y oportuna, así como, expresar todo tipo de opiniones, por otro lado, las desventajas apuntan a que existen comentarios poco oportunos, falsos, incluso molestos o hirientes hacia algunos usuarios.

Este tipo de comentarios se conocen como ciberbullying, que se interpreta cuando un niño o adolescente es molestado, amenazado, acosado o cualquier otra acción que le incomode efectuado por otro niño o adolescente a través de cualquier medio de comunicación con acceso a Internet. Existen muchas formas de ciberbullying dentro de las comunes se encuentran: publicaciones ofensivas y mensajería instantánea que se localizan principalmente en blogs, sitios web, redes sociales o cualquier medio donde expresen ideas públicamente (Ciberbullying, 2016).

En México los casos de ciberbullying van en aumento ante la poca legislación y control que existe sobre las redes sociales, por lo tanto, de acuerdo con cifras descritas por (Posada, 2018) INEGI en 2015, señalo que el 24.5% de los usuarios de Internet de 12 años o más fueron víctimas de alguno tipo de ciberbullying.

También existe el sarcasmo que es una forma indirecta de humor agresivo con la finalidad de burlarse, ridiculizar o de insultar (Aditya Joshi, 2017). Por consiguiente, el problema es a través de textos en frases hirientes es el sarcasmo en forma de ciberbullying que daña a otras personas, por ejemplo “@MorganaleFay_ @AcProcoyoacan @manuelnegrete @Alcaldia_Coy Es que como le dio #coronavirus ... no puede trabajar.. es sarcasmo. De todos modos nunca ha hecho nada el alcalde @manuelnegrete22”.

El sarcasmo forma parte del ciberbullying puesto que quien lo utiliza lo hace con la finalidad de herir a otros usuarios, es muy complejo detectarlo ya que intervienen varios factores como el contexto en el que está escrito, los emoticonos si es el caso, y las palabras ya que en México existe gran diversidad de significados para las palabras en comparación con otros países, motivo por el cual este trabajo se centra en descubrir sarcasmo en textos cortos (tuits) en español.

1.4 Alcances y limitaciones

El presente trabajo, analiza tuits en el idioma español en México y se centra únicamente en la detección de sarcasmo en textos relacionados con el tema de COVID-19 a partir del año 2020. Debido a la complejidad de detección de sarcasmo en los tuits y el tiempo que demanda la detección de sarcasmo de todo el texto en

un tuit, la investigación, hace un análisis únicamente de los *hashtags* que devuelven los tuits y no se indica el nivel de sarcasmo, además de que para obtener más datos de Twitter implica invertir más tiempo de recolección debido a que se obtiene de acuerdo con lo que un usuario tuitear.

1.5 Organización de la tesis

La tesis se encuentra organizada de la siguiente forma:

En el Capítulo 2, se realiza el análisis del estado del arte. Se revisan los principales trabajos que analizan tuits, detección de sarcasmo y cyberbullying por medio de la red social Twitter. Posteriormente, en el Capítulo 3 se presentan los fundamentos teóricos relacionados con el problema a resolver. Los principales temas son: modelo KDD, recolección y limpieza de datos, minería de datos, evaluación de modelos de clasificación y el sarcasmo. En el Capítulo 4 se muestran los pasos metodológicos a seguir para detectar sarcasmo en tuits, además, se presentan algunos experimentos usando dos corpus distintos y algunos algoritmos de clasificación comparando los resultados mediante la métrica *F-measure*. Finalmente, en el Capítulo 5 se presentan las conclusiones y posibles trabajos a futuro que se derivan de este trabajo.

Capítulo 2

2 Estado del arte

En este capítulo se describen los trabajos más relevantes que han abordado la detección de sarcasmo en tuits en el idioma español. Se presentan Tablas que resumen las técnicas aplicadas, los datos empleados y los resultados obtenidos.

2.1 Redes sociales

En México el crecimiento exponencial de internautas de Internet se ha observado notablemente a partir del 2006 hasta el 2019 como muestra la gráfica en la Figura 2-1 el 2018 con un número de internautas de 82.7 millones para el 2019 el incremento fue de 5.4% con 87.4 millones de internautas.




Figura 2-1. Grafica de Usuarios de Internet en México 2006-2018. Imagen obtenida de (Asociación de internet MX, 2021, pág. 4).

En 2020, aumentan significativamente la mayoría de las actividades digitales en México. Ganan terreno: mail, comercio electrónico y la banca, sin embargo, transporte decrece debido al confinamiento.

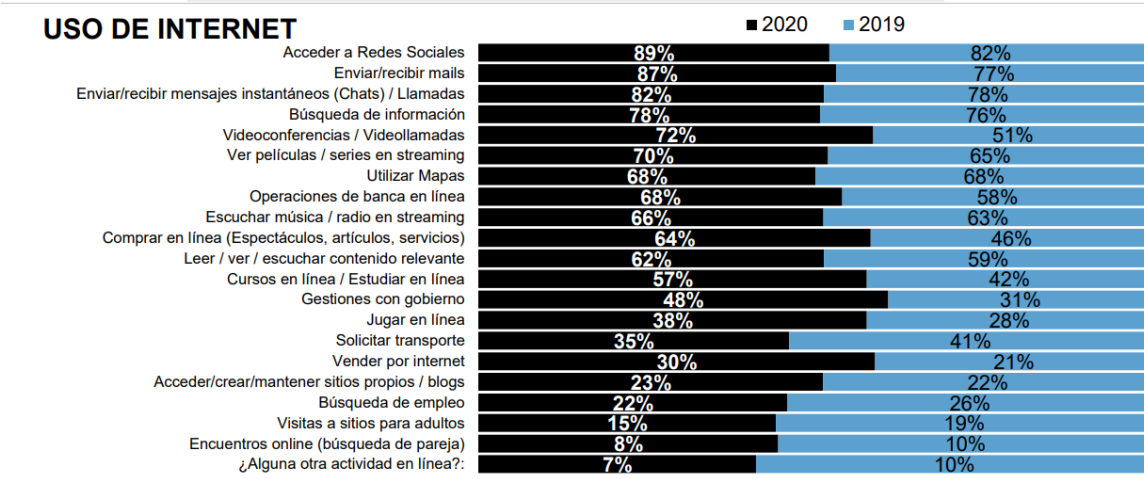


Figura 2-2. Actividades en línea. Imagen obtenida (Asociación de internet MX, 2021, pág. 13).

De acuerdo con la Asociación de Internet MX la actividad de los usuarios se distribuye como se muestra en la Figura 2-2, el uso está repartido en diferentes actividades, ya que debido a la pandemia la mayoría de las actividades se mudaron de manera virtual a comparación del año 2019, donde las redes sociales se concentraban en un porcentaje de 82%, en el año 2020, el uso del internet incremento a 89% del total del tiempo invertido al Internet dado que “las redes sociales en esta época de contingencia, significaron tiempo relevante para los internautas en México, 4 horas y 8 minutos de conexión diarios, 37 minutos más que en 2019 y no solo eso, significaron el 31% del tiempo de conexión diario a Internet en México” (Asociación de internet MX, 2021, pág. 25).

Con la llegada de la pandemia de la COVID-19, la adaptación a las actividades que comúnmente se realizaban consigo ha traído que los usuarios inviertan más tiempo

desarrolladores que permite hacer uso de sus datos y así descubrir información relevante sobre ellos y generar investigación destacada.

Durante el año 2006 Twitter solo era un servicio de SMS que permitía comunicarse en grupos pequeños de personas, donde te preguntaban ¿Qué estás haciendo?, que debía ser escrito en menos de 140 caracteres y enviarse sus actualizaciones al número 40404. En ese momento, el proyecto de Twitter estaba en paralelo con otros proyectos, los cofundadores Jack Dorsey, Biz Stone y Evan Williams crearon esta idea dentro de la compañía de podcasting Odeon, en un principio el proyecto era llamado twttr.

Y no fue hasta el 21 de marzo del 2006 donde el cofundador Jack Dorsey publicó el primer mensaje de Twitter de acuerdo al autor (Petersel & Schindler, 2012) el tweet contenía “just setting my twttr - ajustando mi twttr ”. Posteriormente en marzo del 2007 Twitter tuvo éxito debido a una conferencia donde en grandes pantallas se mostraban los tuits enviados por los que asistieron a dicha conferencia, dando un nuevo poder a los mensajes cortos y por consiguiente inicio a una gran red social que llegó a lo que se conoce hoy en día.

2.3 Detección de sarcasmo

El sarcasmo en la vida diaria es muy fácil de entender o al menos de saber que estas siendo víctima de él, pero actualmente en las redes sociales además de crecer como medio de comunicación también ha crecido la forma en que se pueden utilizar el sarcasmo como una forma de *bullying* a través de estos medios de comunicación.

El sarcasmo es una forma indirecta de humor agresivo con la finalidad de burlarse, ridiculizar o de insultar a través de texto cortos en frases hirientes, por ejemplo: en el siguiente tuit, se puede observar que el texto es hiriente:

```
"@MorganaleFay @AcProcoyoacan @manuelnegrete @Alcaldia Coy Es  
que como le dio #coronavirus ... no puede trabajar.. es sarcasmo.  
De todos modos, nunca ha hecho nada el alcalde @manuelnegrete22"
```

2.4 Detección de sarcasmo cyberbullying en Twitter

Hoy en día las redes sociales tienen un gran impacto en la sociedad y el uso que le dan trae consigo desafíos, por consiguiente, nace el interés de analizar esos datos, detectar patrones que descubran comportamientos a partir de los textos que escriben las personas.

Existen diferentes trabajos en los que se han utilizado las redes sociales, por ejemplo, análisis de sentimientos, campañas de marketing, entre otros y más recientemente para detectar acoso o actividades que pueden dañar o agredir a los usuarios. Una de las redes sociales más utilizadas para el análisis de textos es Twitter debido al extenso número de usuarios con los que cuenta y a la variedad de textos que pueden ser escritos. Una de las áreas que se ha explorado es la que utiliza Twitter para realizar análisis de sentimientos con la finalidad de saber cuándo existe intimidación a través de las emociones que se expresan en los tuits dentro de las conversaciones que se generan en esta red social.

En la Tabla 2-1 se muestra un resumen de algunos trabajos relacionados con la detección de sarcasmo a través de Twitter. En la tabla se puede observar la finalidad del trabajo, las técnicas utilizadas, los resultados obtenidos y el conjunto de datos utilizados.

Cita	Objetivo	Técnica	Resultados	Datos empleados
(Arthur Patch, 2015)	Dar a conocer cuándo existe acoso escolar tras identificar comportamiento agresivo generado en tuits escritos en conversaciones entre usuarios.	Analizador emocional el cual utiliza diccionarios emocionales/ léxicos.	El uso de análisis emocional les fue efectivo para determinar comportamiento agresivo para identificar relaciones de acoso escolar.	Se utiliza un corpus de 548,780 tuits obtenidos de las APIs, search y streaming.
(Monteiro e Silva, Félix F. da Silva, & De Souza Dias, 2017)	Detectar automáticamente si un tuit contiene rastro de acoso.	Clasificadores Naive Bayes, Logistic Regression y SVM (Support Vector Machine).	Demostró que es posible utilizar herramientas para la detección automática de Bullying en Twitter en idioma portugués.	El corpus es de 48,262 extraídos de la API de streaming de Twitter.
(De Francisco Rus, 2018)	Construcción de un clasificador supervisado para la detección de cyberbullying.	Clasificadores Naive Bayes, Random Forest, Support Vector Machines (SVM) y K Vecinos más cercanos.	Se determina que los mejores resultados los ofrece el algoritmo Support Vector Machine con BoW ya que consigue un grado de precisión de casi 64% y un recall (exhaustividad) del 73%.	El corpus es de 48,150 tuits extraídos de la API de Twitter.
(Chatzakou Despoina & Vakali, 2017)	Detectar acoso y el comportamiento agresivo en Twitter.	Se usa la herramienta de CrowdFlower para el etiquetado y para usar los clasificadores de aprendizaje automático.	Se demuestra que los algoritmos de clasificación de aprendizaje automático pueden detectar con precisión a los usuarios que exhiben acoso y comportamiento agresivo, con más del 90% de AUC.	Se recopilan dos conjuntos de tuits: Tuits aleatorios de 1M y un conjunto de 650k tuits recopilados de la API de Streaming de Twitter usando 309 hashtags relacionados con

				la intimidación y el discurso de odio.
(Sanchez & Kumar, 2020)	Detección de acoso escolar con análisis de sentimientos en la red social Twitter.	Clasificador Naïve Bayes.	Análisis de sentimientos para detectar casos de acoso escolar en Twitter. Clasificador tiene una precisión de 70%.	Se utiliza un corpus de 960 tuits extraídos de la API de Twitter.

Tabla 2-1. Trabajos relacionados al proyecto de investigación de detección de acoso o cyberbullying en tuits.

De acuerdo con, la Tabla 2-1 se desarrolla un trabajo acerca del tema de Detección de bullying en Twitter con léxicos de emoción en donde explica que ha utilizado diccionarios emocionales /léxicos para asignar sentimientos y emociones a cada palabra en una oración de los tweets (Arthur Patch, 2015). En su estudio las emociones asignadas de tuits las graficaron y utilizaron evaluadores para clasificar las relaciones de diferentes conversaciones junto con tuits para la detección de acoso donde compararon las emociones que comúnmente usan y las poco usuales cuando es efectuado el acoso, determinaron al final que de acuerdo con los resultados arrojados no había mejor precisión al usar esos dos parámetros.

Otros autores, como (Monteiro e Silva, Félix F. da Silva, & De Souza Dias, 2017) utilizaron Twitter para detección de acoso en donde aplicaron técnicas de Machine Learning a un conjunto de datos y detectar automáticamente si un tuit contiene rastro de acoso, para ello realizaron una comparación de clasificadores para usar el que mejores resultados les mostro; además de este trabajo está el del autor (De Francisco Rus, 2018) que desarrolló el tema acerca de Construcción de modelos de clasificación automática para la detección del acoso, construyó junto con un equipo de trabajo un clasificador supervisado para la detección de acoso en donde aplicaron varios algoritmos para mejorar sus resultados y obtener una mejor

detección, finalmente después de las limitaciones para tener la información correcta referente al acoso sus resultados demostraron un 73% en clasificación y con una precisión de 64%.

En otros trabajos (Chatzakou Despoina & Vakali, 2017) utilizaron Twitter para detectar el acoso y comportamiento agresivo, para ello en su metodología esta propuesto estudiar cómo es un agresor y acosador que lo diferencia de los demás usuarios a lo que llegaron fue que las características más comunes de un acosador son estar poco reconocido y activo en las redes sociales, por otro lado es común que un agresor sea popular entre la comunidad de Twitter pero en sus publicaciones incluyen más el contenido negativo estas características mencionadas permiten dar mayor efectividad a su clasificador sobre cómo detectar acoso y comportamiento agresivo con una efectividad del 90% de AUC. En cambio (Sanchez & Kumar, 2020) utilizaron minería de datos en redes sociales para la detección de acoso escolar a través de análisis de sentimientos para ello utilizaron mensajes de Twitter (tuits) implementando un clasificador Naive Bayes en el que incluyeron términos de abuso que le permitió tener un 70%de precisión.

Frente a los casos de ciberbullying que existe en las redes sociales y al ser un tema muy amplio existen casos de sarcasmo una forma de ciberbullying puesto que el sarcasmo es una forma indirecta de agredir y ofender a otro usuario a través de textos cortos. A continuación, se resumen algunos trabajos donde su estudio se enfoca en la detección de sarcasmo, ironía o rumores en Twitter Tabla 2-2.

Cita	Finalidad	Técnica	Resultados	Datos
(Aditya Joshi, 2017)	Hacer una recopilación de trabajos que hacen referencia a lo usado para detectar el sarcasmo.	-Learning Algorithm -Deep Learning-Based Approaches.	Describen conjunto de datos, valores, rendimientos y técnicas que pueden ser usadas, así como los desafíos al detectar sarcasmo.	Corpus tiene tuits extraídos manualmente y de la API de Twitter.
(Bamman & A. Smith, 2015)	Utilizaron información extralingüística del contexto del tuit con propiedades del autor, audiencia y entorno comunicativo que agregaron mejores características para lograr la detección del sarcasmo.		Todas las características extralingüísticas para el entrenamiento dieron mejoras al modelo, pero la que produjo mayor mejora fueron las derivadas del autor.	El corpus es extraído a base de dos hashtags #sarcasm #sarcasticun con un total de 19, 534 tuits.
(Rajadesingan, Zafarani, & Liu, 2015)	Emplearon comportamiento y estudios psicológicos para construir un marco de modelado conductual sintonizado para detectar el sarcasmo.	SCUBA, un marco de modelado de comportamiento para la detección de sarcasmo.	Demostraron que el SCUBA es efectivo para detectar tuits sarcásticos. SCUBA considera los aspectos psicológicos y conductuales del sarcasmo y aprovechando la información histórica de los usuarios para decidir si los tweets son sarcásticos o no.	Su corpus se divide en dos partes -400,000 tuits con hashtags de sentimientos positivos como #love, #happy, #amazing. -400,000 tuits con hashtags de sentimientos negativos como #sad, #depressed, #hate. Recolectados de las APIs de Twitter.
(Jasso & Meza, 2016)	Establecieron un sistema base de clasificación usando características	Máquinas de soporte vectorial y selvas aleatorias	Observaron que las características basadas en caracteres son	Corpus de expresiones irónicas recolectado manualmente con un total de corpus

	simples al nivel de palabras y caracteres para entradas en español.	usando n-gramas.	buenos indicadores para la detección de ironía, y generalmente ofrecen una buena base para el español.	contiene aproximadamente 14, 500 tuits irónicos únicos y 670, 000 tuits no irónicos únicos.
(A.Saravananaraj, 2019)	Detectaron la aparición de ciberacoso y rumor en la red social Twitter.	Clasificadores Naïve Bayes y Random Forest.	Su modelo propuesto les arrojó mejores resultados al detectar cyberbullying y rumores en una sola aplicación.	Su corpus lo extrajeron de una data set.
(A & D, 2020)	Realizar análisis de sarcasmo en texto de conversaciones de usuarios de Twitter y foros de Reddit para detectar automáticamente temas derivados del ciberacoso.	Aprendizaje automático, aprendizaje profundo (RNN-LSTM) y BERT (codificador bidireccional Representaciones de Transformers) para identificar el sarcasmo.	Compararon el rendimiento en función de los enfoques obteniendo la mejor F1 puntajes como 0.722, 0.679 para los foros de Twitter y foros de Reddit respectivamente .	Corpus de datos de Twitter: 2500 tuits de sarcasmo y 2500 tuits de no sarcasmo y 1800 tuits de prueba. Reddit: 4400 tuits de conversión, 2200 tuits sarcásticos, 2200 tuits no sarcásticos, y 1800 tuits de prueba.

Tabla 2-2. Trabajos relacionados con el proyecto de investigación detección de sarcasmo o ironía en tuits.

En la Tabla 2-2 se muestran los trabajos relacionados, como el de (Aditya Joshi, 2017) quien utilizó Twitter en una recopilación de trabajos donde señala los desafíos que trae realizar detección de sarcasmo en textos, además, describe conjunto de datos, tendencias, enfoques, técnicas etc., y señala las características y tipos de sarcasmos de suma importancia para comprenderlo, en su trabajo destacan tres hitos, extracción de patrones semi-supervisada para identificar sentimientos implícitos, uso de supervisión basada en hashtag e incorporación de contexto más allá del texto de destino. Del mismo modo autores como (Bamman & A. Smith, 2015) enfatizan que detectar el sarcasmo es muy complejo, demostraron en su trabajo

que al incluir información extralingüística del contexto del tuit agregando propiedades del autor, audiencia y entorno comunicativo obtuvieron mejores características para lograr una detección más efectiva del sarcasmo.

En su trabajo (Rajadesingan, Zafarani, & Liu, 2015) muestran que para la detección de sarcasmo no utilizan claves léxicas ni lingüísticas si no que para lograr su objetivo identificaron primero tuits anteriores que realizo el usuario en donde emplearon estudios conductuales y psicológicos que les permitió construir un modelo conductual ajustado para la detección del sarcasmo. Otro trabajo y que se realizó en México los autores (Jasso & Meza, 2016) establecieron un sistema de clasificación usando características simples a nivel de palabras y caracteres para entradas en español de la red social Twitter para detectar la ironía.

Se concluye que existen diferentes metodologías, técnicas y propósitos donde emplearon la red social Twitter en todas con referencia a acoso, ciberbullying, sarcasmo u ironía. La aplicación que tiene cada una de ellas les ha permitido entender el comportamiento que existe por este medio y la relación que existe con otros usuarios. Además de los avances que han logrado en el estudio de los datos dentro de este medio social.

De acuerdo (A.Saravanaraj, 2019) utilizó Twitter para detectar ciberbullying para ello identificaron mediante algoritmos de aprendizaje automático el ciberbullying y los rumores los mediante técnicas sintácticas y semánticas en tuits, por consiguiente la aparición de ciberbullying y rumores en la misma aplicación les permitió brindar

mejores resultados a su clasificador además de que agregaron detectar el sexo y edad de las personas tuiteadas añadiendo más parámetros a su detección.

Así mismo los autores (A & D, 2020) desarrollaron un trabajo donde explican cómo realizaron análisis de sarcasmo en conversaciones entre usuarios en foros de Twitter y Reddit de quien también extrajeron tuits, en su trabajo, explican como el análisis del sarcasmo ayuda a evitar que los insultos, las heridas y el humor afecten a alguien con base en 3 técnicas que aplicaron: aprendizaje automático, aprendizaje profundo y BERT (codificador bidireccional Representaciones de Transformers) para identificar el sarcasmo con dichas técnicas encontraron los mejores modelos aplicándolo a ambos sitios de recolección de los datos esto de acuerdo a los puntajes de sus evaluadores.

2.5 Síntesis

En este capítulo se presentan los trabajos relacionados con la detección de acoso o ciberbullying en tuits, así como la detección de sarcasmo o ironía en tuits. Se presenta una tabla comparativa de estos trabajos donde se muestran las técnicas empleadas y los resultados obtenidos.

Capítulo 3

3 Marco Teórico

El capítulo 3 está dedicado a los temas relacionados con el problema identificado. Inicia analizando el modelo KDD (Descubrimiento de Conocimiento en Bases de Datos), algunos algoritmos de clasificación, algunas métricas de evaluación de modelos de clasificación y los aspectos teóricos del sarcasmo.

3.1 Modelo KDD

El estudio de este trabajo este guiado a través del proceso KDD. El proceso KDD Knowledge Discovery in Database, o Descubrimiento de Conocimiento en Bases de Datos de acuerdo con los autores (Chatzakou Despoina & Vakali, 2017) se define como “el descubrimiento de conocimiento en bases de datos, que combina técnicas del aprendizaje de máquina, reconocimiento de patrones, estadística, bases de datos, y visualización para automáticamente extraer conocimiento (o información), de un nivel bajo de datos (bases de datos)”.

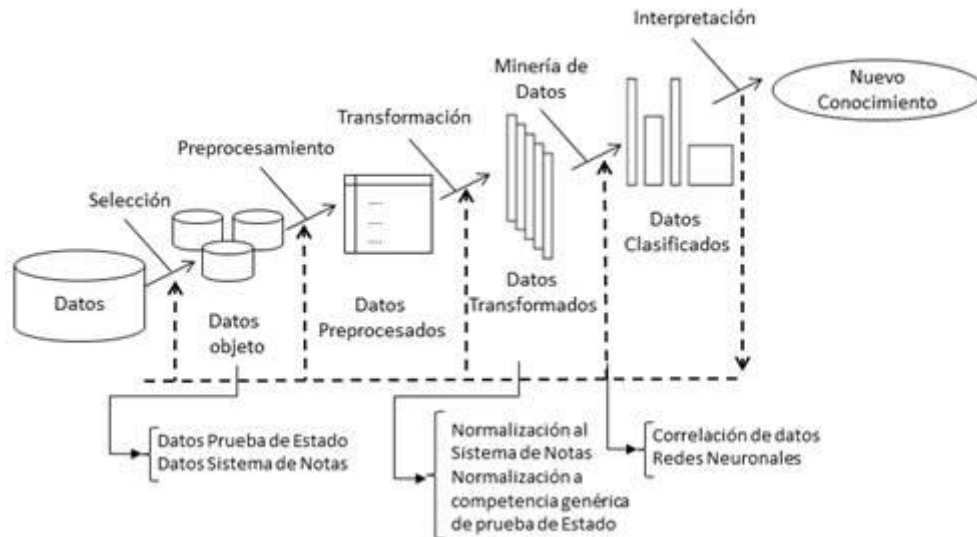


Figura 3-1. Etapas del KDD (García-González, Sánchez-Sánchez, Orozco, & Obredor, 2019).

El proceso KDD se compone de varias etapas que pueden observarse en la Figura 3-1 propuesta por (García-González, Sánchez-Sánchez, Orozco, & Obredor, 2019), en la que se puede distinguir cinco fases que se describen a continuación.

El proceso KDD tiene una entrada y una salida, en la entrada se debe tener los datos que se seleccionan de las diferentes fuentes de donde se determine que serán obtenidos y extraídos, también se toma consideración el formato y la selección de variables de esos datos para determinar el tipo de almacenamiento que tendrá el repositorio de datos.

- **Selección de fuentes de datos:** Esta fase consiste en extraer los datos provenientes de diversas fuentes de datos, por lo que es necesario que se apliquen técnicas de análisis exploratorio de datos y encontrar la correlación y homogeneidad entre los datos para así realizar una buena distribución de los datos.

- **Pre procesamiento:** En esta fase se realiza la limpieza de datos se determinan cuáles son los valores atípicos, erróneos, faltantes o incorrectos y se observa de qué manera impactan con el resto de los datos para que finalmente sean corregidos o eliminados.
- **Transformación de datos:** Esta fase consiste en hacer normalización de los datos con el objetivo de reducir la redundancia en ellos, pasa por un proceso dividido en 3 partes, integración de datos, juntar las diferentes colecciones para terminar con un único conjunto de datos, transformación de datos, aplicar las modificaciones sintácticas necesarias y por ultimo reducción de datos, esta última parte de proceso el tamaño va a cambiar si se realizó algún cambio en la presentación de los datos o si hubo alguna reducción de las variables que están consideradas para el estudio de los datos.
- **Minería de datos:** Esta fase es una de las más importantes puesto que es donde se hace la búsqueda de patrones de interés aplicando las técnicas y algoritmos necesarios. Se definen de acuerdo con lo que se va a realizar con los datos seleccionando el tipo de técnica a utilizar, en general hay dos, técnicas descriptivas y técnicas predictivas, de acuerdo con la técnica posteriormente se seleccionan los algoritmos que mejor se adecuen al muestreo.
- **Evaluación e interpretación de patrones:** Esta fase consiste en evaluar los modelos e identificar los patrones interesantes que representan conocimiento, además de aplicar los diferentes análisis para determinar el porcentaje de error existente en los modelos, como análisis ROC, Bootstrap,

intervalos de confianza etc. En la interpretación de ser necesario de regresa a fases anteriores para mejorar o ajustar partes del proceso y así tener resultados más eficientes de igual manera se realiza el análisis de los resultados de necesitarse existen técnicas que te ofrecen una mejor comprensión de los patrones descubiertos.

Por último, la salida del proceso KDD es el conocimiento que consiste en dar a conocer el nuevo conocimiento generado y colocarlo a disposición de los usuarios que lo requieran. Para efectos de este trabajo de tesis se dividirán las tareas en tres etapas: recolección y limpieza, minería de datos y evaluación, las cuales se detallan a continuación.

3.2 Recolección y limpieza

De acuerdo a (DigitalTroupe Brand Services, 2015) Twitter es un servicio que permite que los grupos de amigos, familiares y compañeros de trabajo se comuniquen y estén en contacto a través de mensajes rápidos y frecuentes. Las personas publican tuits, que pueden contener información en diversos formatos imágenes, videos, enlaces y texto. Estos mensajes se publican en tu perfil, se envían a tus seguidores y también se pueden encontrar a través de la búsqueda de Twitter. De acuerdo a (DigitalTroupe Brand Services, 2015) en Twitter los tuits se clasifican en 4:

- ✓ **Tuits Normales:** Son todos los mensajes que se publican en tu perfil de Twitter y que les aparecen a los seguidores.

- ✓ **Menciones:** Son para mencionar a usuarios, lleva un @ seguido del nombre de usuario y que se encuentra dentro del tuit publicado, por ejemplo, Hola como estuvo tu día hoy @nombredeusuario.
- ✓ **Respuestas:** Una vez publicado un tuit si este es respondido por algún seguidor o usuario, te aparece un @ seguido de su usuario y la respuesta que se haya escrito.
- ✓ **Mensaje directo «DM»:** La función donde te pueden enviar un mensaje personal solo si se siguen por ambas partes, y estos no son públicos y de ser necesario se pueden eliminar, las conversaciones que realices pueden ser privadas o grupales.

Radiografía de un tuit

Lo que el usuario ve de un tuit

Los tuits están estructurados de una forma organizada todos contienen información de los usuarios y del propio tuit, a continuación, se explica cómo está formado un tuit tanto para la vista del usuario.



Figura 3-2 Anatomía de un tuit hacia el usuario. (DigitalTroupe Brand Services, 2015).

En la Figura 3-2 muestra cómo se compone un tuit, el cual incluye avatar imagen o foto del dueño de esa cuenta de Twitter, nombre, la mención en caso de que sea usado, nombre de usuario, el texto del tuit, la fecha y hora de publicación del tuit, botones para interactuar con ese tuit o el usuario que lo creó y por último el hashtag que marca palabras claves o temas.

Así mismo el hashtag puesto que permitió hacer el estudio ya que los hashtags más que una simple palabra que se hace en tendencia da la pauta de que tanta gente hace uso de ella y los que retuitean escriben sobre el tema.

Lo que no se ve de un tuit

En Twitter el código bajo el que es almacenado cada tuit contiene información y extensa de cada usuario, así como del propio tuit, a continuación, se muestra las partes de un tuit.

Twitter incluye en el código no visible de cada tuit una extensa y valiosa información sobre muchos más que el contenido que vemos en los 280 caracteres. (DigitalTroupe Brand Services, 2015).

Partes de un tuit internamente	
Variable	Información
<id>	identificador único del tuit
<source>	App utilizada para crearlo
<truncated>	si fue recortado (>140 caracteres)
<id >	identificador único de usuario
<time_zone>	zona horaria
<description>	descripción personal (Bio)
<lang>	mi lengua por defecto
<statuses_count>	número de tuits que he escrito
<protected>	si mi cuenta está protegida
<create_at>	fecha de creación de la cuenta
<in_reply_to_id/>:	en caso de que una contestación guardaría a que tuit contestamos, identificador y nombre de usuario
<verified>:	si mi cuenta esta verificada
<followers_count>:	número de seguidores
<Friends_count>:	número de amigos
<withheld>:	si esta censurado por quien - y donde estoy censurado por quien.
<geo_enabled><location>:	geolocalización e incluso detalles acerca de la población, el barrio y las coordenadas geográficas aproximadas desde donde se emitió el mensaje.
<lang>:	si fue reclamado por derechos de autor

Tabla 3-1 Partes de un tuit internamente (DigitalTroupe Brand Services, 2015).

Así mismo la Tabla 3-1 describe las partes en que se divide y es devuelto un tuit internamente por código, un tuit trae gran cantidad de información que no se aprecia

a simple vista, como el “id” del usuario y del tuit hasta la geolocalización aproximada de donde fue emitido.

3.3 Minería de datos

Para minería de datos los algoritmos son un conjunto de operaciones sistemáticas que permiten hacer cálculos y hallar solución de problemas y donde se crea un modelo a partir de datos. Además, permite crear modelos donde a partir de datos que se le proporcionan al algoritmo busca patrones y con los resultados que obtiene luego del análisis crea el modelo de minería de datos. De acuerdo con (Minewiskan, 2018) los algoritmos se clasifican en 5 tipos:

- **Algoritmos de clasificación:** predicen una o más variables discretas, basándose en los demás atributos del conjunto de datos.
- **Algoritmos de regresión:** predicen una o más variables numéricas continuas, como pérdidas o ganancias, basándose en otros atributos del conjunto de datos.
- **Algoritmos de segmentación:** dividen los datos en grupos, o clústeres, de elementos que tienen propiedades similares.
- **Algoritmos de asociación:** buscan correlaciones entre diferentes atributos de un conjunto de datos. La aplicación más común de esta clase de algoritmo es la creación de reglas de asociación, que pueden usarse en un análisis de la cesta de compra.
- **Algoritmos de análisis de secuencias:** resumen las secuencias frecuentes o episodios en los datos, como una serie de clics en un sitio web o una serie

de eventos de registro que preceden al mantenimiento del equipo.
(Minewiskan, 2018).

De acuerdo con la investigación del tema de tesis, se utilizan algoritmos de clasificación dado que se hacen predicciones de variables que se determinan del corpus de datos que se describen a continuación. Para minería de datos la clasificación es considerada una técnica supervisada, ya que organiza mediante un atributo llamado clase busca aquellos atributos que corresponda o no al concepto por el cual se está buscando hacer la clasificación.

El autor (Haro, Zúñiga, Vera Rojas, & Villa, 2018) dice que la clasificación es “la habilidad para adquirir una función que mapee (clasifique) un elemento de dato a una de entre varias clases predefinidas”, continuación se describe más a detalle cómo funciona la clasificación.

Se tiene un objeto, del cual lo componen ciertas variables o atributos que lo caracterizan.

$$X \rightarrow \{X_1, X_2, \dots, X_n\} \quad (3.1)$$

La finalidad de la función de clasificación es clasificar el objeto en alguna de las clases

$$C = \{C_1, \dots, C_k\} \quad (3.2)$$

$$f: X_1 \times X_2 \times \dots \times X_n \rightarrow C \quad (3.3)$$

De acuerdo con las fórmulas representativas, en el objeto deben ser seleccionadas las variables o atributos que mejor sirvan, puesto que en la clasificación de acuerdo con esos atributos o variables se realiza la asignación de la clase ya que “las características o variables elegidas dependen del problema de clasificación”. (Haro, Zúñiga, Vera Rojas, & Villa, 2018).

3.3.1 Naive Bayes

Naive Bayes es un algoritmo de clasificación, utilizados para el aprendizaje automático y/o machine learning. De acuerdo con el autor (Roman, 2019), Naive Bayesian classifier proporciona un enfoque simple, con semántica clara, para representar, usar y aprender el conocimiento probabilístico. Este método es usado para tareas supervisadas puesto que su principal objetivo es hacer la predicción de acuerdo con una clase definida con ciertas características, en las cuales se introducen datos para conocer cuántos contienen características de la clase antes definida.

El método está diseñado para usarse en tareas de inducción supervisadas, en las que el objetivo de rendimiento es predecir con precisión la clase de instancias de prueba y en las que las instancias de capacitación incluyen información de clase.




Figura 3-3. Un clasificador bayesiano ingenuo representado como una red bayesiana en la que los atributos predictivos (X_1, X_2, \dots, X_k) son condicionalmente independientes dado el atributo de clase (C) (H. John & Langley, 1995).

Gráficamente un clasificador bayesiano se representa como en muestra la Figura 3-3 donde la C que está en el primer nodo representa la clase, y los nodos debajo de este representan las instancias que tienen características de la clase. De acuerdo con (H. John & Langley, 1995) el siguiente ejemplo muestra la forma en cómo funciona un algoritmo Naive Bayes expresado en una fórmula.

Ejemplo: Sea C la variable aleatoria que denota la clase de una instancia y sea X un vector de variables aleatorias que denoten los valores de los atributos observados. Además, c representa una etiqueta de clase particular y x representa un vector de valor de atributo observado particular.

Dado un caso de prueba x para clasificar, uno simplemente usa la regla de Bayes para calcular la probabilidad de cada clase dado el vector de valores observados para los atributos predictivos,

$$p(C = c | X = x) = \frac{p(C=c)p(X=x|C=c)}{p(X=x)} \quad (3.4)$$

Para después predecir la clase más probable. Aquí $\mathbf{X} = \mathbf{x}$ representa el evento de que

$$X_1 = x_1 \wedge X_2 = x_2 \wedge \dots \wedge X_k = x_k. \quad (3.5)$$

Debido a que el evento es simplemente una conjunción de asignaciones de valor de atributo, y debido a que se supone que estos atributos son condicionalmente independientes, se obtiene

$$\begin{aligned} p(X = \mathbf{x} | C = c) &= p\left(\bigwedge_i X_i = x_i | C = c\right) \\ &= \prod_i p(X_i = x_i | C = c) \end{aligned} \quad (3.6)$$

que es simple de calcular para casos de prueba y estimar a partir de datos de entrenamiento. Generalmente uno no estima directamente la distribución en el denominador de la Ecuación 3.1, ya que es solo un factor de normalización; en su lugar, se ignora el denominador y luego se normaliza de modo que la suma de $p(C = c | X = \mathbf{x})$ sobre todas las clases sea uno.

3.3.2 Random Forest

Un modelo Random Forest está formado por un conjunto (ensemble) de árboles de decisión individuales, cada uno entrenado con una muestra aleatoria extraída de los datos de entrenamiento originales mediante bootstrapping de acuerdo con (Amat Rodrigo, Arboles de decision, Random Forest, Gradient Boosting y C5.0, 2015). Esto quiere decir que implica que cada árbol individual va haciendo distribuciones

en sus nodos hasta llegar a un nodo final y para realizar la predicción de una nueva observación se realiza mediante la recolección de las predicciones de los árboles individuales y que a su vez estos forman el modelo.

Para conocer la predicción del algoritmo Random Forest de acuerdo con (Amat Rodrigo, Arboles de decision, Random Forest, Gradient Boosting y C5.0, 2015) se describe a continuación en un ejemplo:

En un principio se toma como ejemplo que existen 10 observaciones cada una con un valor de variable respuesta Y y unos predictores X .




Figura 3-4. Predicción con Random Forest (Amat Rodrigo, Arboles de decision, Random Forest, Gradient Boosting y C5.0, 2015).

La Figura 3-4 muestra gráficamente como sería la predicción de una nueva observación de un modelo Random Forest, en cada árbol, el camino hasta llegar al nodo final está resaltado. En cada nodo terminal se detalla el índice de las observaciones de entrenamiento que forman parte.

El valor predicho por cada árbol es la media de la variable respuesta Y en el nodo terminal. Acorde a la imagen, las predicciones de cada uno de los tres árboles (de izquierda a derecha) es:

$$\hat{y}_{arbol_1} = \frac{24+2+20}{3} = 15.33333 \quad (3.7)$$

$$\hat{y}_{arbol_2} = \frac{18+24}{2} = 21 \quad (3.8)$$

$$\hat{y}_{arbol_3} = \frac{18+24+2+20}{4} = 16 \quad (3.9)$$

La predicción final del modelo es la media de todas las predicciones individuales:

$$\hat{\mu} = \frac{15.33333+21+16}{3} = 17.4 \quad (3.10)$$

3.3.3 J48

El algoritmo J48 es un clasificador de tipo árbol de decisión el cual genera gráficos de tipo árbol y que permite tomar decisiones usando las reglas generadas por el algoritmo. De acuerdo con (Mosquera, Parra Osorio, & Castrillón , 2016) un algoritmo J48 construye árboles de decisión de un sistema de datos del entrenamiento de la misma forma que el algoritmo ID3, que usa el concepto de entropía de la información. Los datos del entrenamiento son un sistema $S = s_1, s_2, \dots$ de muestras ya clasificados. Cada ejemplo $s_i = \{x_1, x_2, \dots\}$ es un vector donde x_1, x_2, \dots representan los atributos o características del ejemplo. Los datos de entrenamiento son aumentados con un vector $C = \{c_1, c_2, \dots\}$ donde c_1, c_2, \dots representan la clase a la que pertenece cada muestra. J48 es una extensión del algoritmo ID3 desarrollado anteriormente por Quinlan. Los árboles de decisión generador por J48 pueden ser usados para clasificación, y por esta razón, J48 está casi siempre referido como un clasificador estadístico.

3.3.4 Máquinas de Vector Soporte (Support Vector Machines, SVMs)

El algoritmo (SVM) Support Vector Machines o máquinas de vectores de soporte, de acuerdo con (Garcia, 2013) son un conjunto de algoritmos de aprendizaje supervisado desarrollados por Vladimir Vapnik, y tiene por objetivo la construcción de un modelo que realiza la predicción de la clase dado una muestra nueva de datos. Estos algoritmos son de las técnicas más poderosas puesto que a partir de la construcción de un hiperplano en un espacio de dimensionalidad donde se separan las clases que se tienen.

El autor (Amat Rodrigo, Cienciadedatos, 2015) explica que en un espacio p -dimensional, un hiperplano se define como un subespacio plano y afín de dimensiones $p - 1$. El término afín significa que el subespacio no tiene por qué pasar por el origen. En un espacio de dos dimensiones, el hiperplano es un subespacio de 1 dimensión, es decir, una recta. En un espacio tridimensional, un hiperplano es un subespacio de dos dimensiones, un plano convencional. Para dimensiones $p > 3$ no es intuitivo visualizar un hiperplano, pero el concepto de subespacio con $p - 1$ dimensiones se mantiene, matemáticamente y considerando un caso de dos dimensiones se describe a continuación en un ejemplo simple la función de un hiperplano:

La definición matemática de un hiperplano es bastante simple. En el caso de dos dimensiones, el hiperplano se describe acorde a la ecuación de una recta:

$$\beta_0 + \beta_1 x_1 + \beta_2 x_2 = 0 \quad (3.11)$$

Dados los parámetros $\beta_0, \beta_1, \beta_2$, todos los pares de valores $x = (x_1, x_2)$ para los que se cumple la igualdad son puntos del hiperplano. Esta ecuación puede generalizarse para p-dimensiones:

$$\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p = 0 \quad (3.12)$$

y de igual manera, todos los puntos definidos por el vector $(x = x_1, x_2, \dots, x_p)$ ($x = x_1, x_2, \dots, x_p$) que cumplen la ecuación pertenecen al hiperplano.

Cuando x no satisface la ecuación 3.13:

$$\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p < 0 \quad (3.13)$$

O bien la ecuación 3.14

$$\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p > 0 \quad (3.14)$$

el punto x cae a un lado o al otro del hiperplano. Así pues, se puede entender que un hiperplano divide un espacio p-dimensional en dos mitades. Para saber en qué lado del hiperplano se encuentra un determinado punto x , solo hay que calcular el signo de la ecuación.

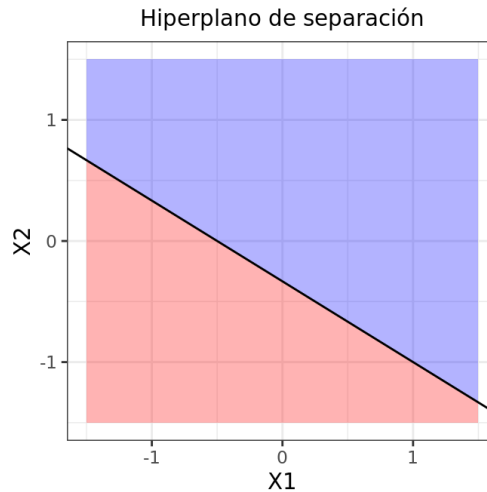


Figura 3-5. Hiperplano de separación (Amat Rodrigo, Cienciadedatos, 2015).

La Figura 3-5 muestra el hiperplano de un espacio bidimensional. La ecuación que describe el hiperplano (una recta) es $1 + 2x_1 + 3x_2 = 0$. La región azul representa el espacio en el que se encuentran todos los puntos para los que $1 + 2x_1 + 3x_2 > 0$ y la región roja el de los puntos para los que $1 + 2x_1 + 3x_2 < 0$.

3.4 Evaluación de los modelos de clasificación

Los modelos de minería de datos una vez que son utilizados en un conjunto de datos, los resultados obtenidos deben evaluarse de acuerdo con técnicas y/o parámetros de evaluación que a continuación de describen más a detalle. De acuerdo a (Marin Castro) existen tres técnicas de evaluación, la primera **validación simple** se utiliza para gran cantidad de datos, donde se elige para pruebas entre el 5 y 50% del total de los datos, **validación cruzada** se divide en dos el conjunto de datos utilizando, la primera parte es para hacer una predicción del segundo y después el proceso de manera inversa, una vez obtenidos los resultados si los errores son pocos se crea un modelo de los dos conjuntos de datos, y por ultimo

validación cruzada con n pliegues el conjunto de datos en esta validación se divide en n partes reservando solo una parte para pruebas y después se repite el proceso para las n partes divididas sin dejar de reservar la de pruebas.

Los parámetros de evaluación de acuerdo con (Miranda & Jheser, 2017) se describen a continuación:

Precisión: Determina la fracción de registros que en realidad resulta ser positiva y que ha sido efectivamente clasificada como positiva. Cuanto mayor sea la precisión, menor será el número de casos erróneamente clasificados como falsos negativos.

Alcance o sensibilidad: Determina la fracción de casos positivos correctamente clasificados.

Ratio falso positivo: Es el porcentaje de casos negativos erróneamente clasificados como positivos.

Ratio falso negativo: Es la proporción de casos positivos erróneamente clasificados como negativos.

Curva ROC: Es una representación gráfica de la relación entre los ratios verdaderos positivos y falsos positivos del clasificador. De acuerdo con lo señalado por (Pang-Ning, 2006), el área bajo la curva ROC (AUC) proporciona un enfoque para evaluar qué modelo es mejor en promedio. Si el modelo es perfecto, entonces su AUC sería igual a 1. Si el modelo se realiza al azar su AUC sería igual a 0,5.

F-Measure: Es una métrica que unifica la precisión y el recall.

3.5 Sarcasmo

El sarcasmo se define como “un acto de habla indirecta cuyo significado no es el mismo que el significado literal de la oración” (Hämäläinen, 2016). Además, destaca que el sarcasmo existe solamente al nivel verbal, es decir, una situación no puede ser sarcástica pero lo que se dice en una situación puede ser sarcástico. Un ejemplo de una situación irónica es el siguiente: el conductor de un coche muere porque se asfixia en el airbag del coche. Aquí lo irónico es que una cosa que debería salvar vidas mata al conductor. Esto, sin embargo, no es sarcástico, pero si un investigador de accidentes, al ver lo ocurrido, dice, “qué bien funcionó el airbag”, se trata de sarcasmo.

3.5.1 Tipos de sarcasmo

De acuerdo con (Aditya Joshi, 2017), se pueden identificar varios tipos de sarcasmo, entre los que destacan:

- **Proposición:** en tales situaciones, la declaración parece ser una proposición, pero tiene un sentimiento implícito involucrado. Por ejemplo, "¡me encanta este lugar!" Esta oración puede interpretarse como no sarcástica, si no se entiende el contexto.
- **Incrustado:** este tipo de sarcasmo tiene una incongruencia incrustada en forma de palabras y frases en sí mismas. Por ejemplo, " mi maestra es muy lectora que adora leer las tareas mal hechas". La incongruencia está incrustada en el significado de la palabra " y el resto de la oración.

- **Likeprefixed:** una frase similar proporciona una negación implícita del argumento que se está formulando. Por ejemplo, "¡Como si te importará!" Es una réplica sarcástica común.
- **Ilocucionario:** este tipo de sarcasmo implica pistas no textuales que indican una actitud opuesta a una expresión sincera. Por ejemplo, poner los ojos en blanco al decir "Sí, claro". En tales casos, las variaciones prosódicas juegan un papel.

3.5.2 Sarcasmo Digital

El sarcasmo de manera presencial como ya se definió en la sección 3.5 y recordando que los factores que influyen son, como esta interactuando la persona físicamente, el tono de voz y la situación por otra parte el sarcasmo digital cambia todos esos aspectos cabe señalar que de acuerdo con (Joshi, Bhattacharyya, & Carman, 2018) describe que el sarcasmo computacional se refiere a enfoques computacionales para procesar el sarcasmo. Menciona que la generación de sarcasmo es la tarea computacional de generar una respuesta sarcástica a una oración de entrada. Por ejemplo: ¿Qué piensas de la nueva película?, se generaría una respuesta sarcástica como, "La película fue tan emocionante como una clase de matemáticas de dos horas", por consiguiente, como no se observa a la persona solo se tiene el texto y el contexto en el que se ha escrito, de manera que lo vuelve un tema complejo para poder ser detectado en redes sociales.

3.6 API de desarrollo

La API de Twitter que proporciona su plataforma de Twitter Developer se usa para diferentes propósitos de análisis de datos, pero en este caso será usada para la extracción y análisis de sus tuits mediante programación.

El API que se usa será **Twitter API v2: Early Access** la cual proporciona diferentes tipos de API para acceso a los datos y principalmente en este estudio se utilizarán la API **Search Tweets** y **Stream Tweets in real-time**.

- **Search Tweets:** los tuits que devuelve el API no son mayor a 7 días.
- **Stream Tweets in real-time:** te permite devolver una muestra aleatoria de tuits en tiempo real.

De acuerdo con (Twitter Developer, 2020) los requisitos para poder acceder a tuis son los siguientes:

1. Solicite una cuenta de desarrollador y reciba la aprobación.
2. Si ya tiene una cuenta de desarrollador, active el nuevo portal de desarrollador.
3. Cree un proyecto y una aplicación de desarrollador asociada en el portal de desarrolladores.
4. Vaya a la página "Claves y tokens" de su aplicación y guarde sus claves API, tokens de acceso y tokens de portador en su administrador de contraseñas.

Los tuits que se extraen de Twitter son devueltos en formato JSON y lo más relevante de toda la información devuelta es el objeto tuit y objeto usuario.

```
{
  "data": {
    "id": "1212092627178287104",
    "text": "These launches would not be possible without the
feedback you provided along the way, so THANK YOU to everyone who
has contributed your time and ideas. Have more feedback? Let us
know ↓ https://t.co/Vxp4UKnuJ9"
  }
}
```

```
{
  "data": {
    "id": "2244994945",
    "name": "Twitter Dev",
    "username": "TwitterDev"
  }
}
```

Estos dos objetos muestran su identificador tuit y su respectivo texto, y en el objeto usuario su identificador, nombre y nombre de usuario.

3.7 Hashtag

Dentro de los componentes que tiene un tuit, el hashtag es una parte relevante porque este posee un gran poder dentro de esta red social ya que la mayor parte de sus tuits están manejados por hashtags, a continuación, se dará a conocer más información sobre este elemento de Twitter.

Un hashtag es cualquier palabra o frase precedida directamente por el símbolo #. Cuando pulses o hagas clic en un hashtag, verás todos los demás tuits que incluyen esa palabra clave o tema. (Glosario, 2021).

El uso de los hashtags han permiti3 la facilidad de comunicaci3n sobre un tema, dado que adem3s poder ser usado para dar m3s visibilidad a un tuit publicado tambi3n ha permitido que cuando se requiera informaci3n sobre alg3n tema sea m3s f3cil la b3squeda en los motores de esta red social ya que al hacer una palabra o frase hashtag permite anexar un v3nculo que facilite su b3squeda del mismo, puesto que para Twitter le permite tener el conocimiento de cuantos usuarios est3n interesados en cierto tema adem3s de saber cu3les son los m3s usados pues despu3s de ser muy usado este pasa hacer tendencia en cierta regi3n o mundialmente aportando todav3a m3s informaci3n sobre sus usuarios.

→ Para que se pueda usar un hashtag solo se necesita una palabra la frase y que al inicio se coloque el s3mbolo “#” para que autom3ticamente se pueda agregar un v3nculo ya que permitir que sea m3s f3cil la b3squeda de dicha palabra o frase.

- En cuanto a los hashtags que existen se pueden encontrar a través del buscador de Twitter o si en algún tuit tiene escrito un hashtag solo se le da clic al hashtag y aparecerán los tuits que lo han utilizado.
- El orden en como redactes un tweet no afectara en la funcionalidad del hashtag este puede ser colocado donde el usuario desee además que si un hashtag es muy usado este pasa a ser tendencia.

Según (Osman, 2018) Un estudio de Buffer sobre los hashtags reveló unos datos interesantes sobre Twitter. Por ejemplo, los tuits con hashtags reciben el doble de cantidad de participación que aquellos sin este, y tuits con uno o más hashtags tienen un 55% más de probabilidad de ser retuitear. Adicionalmente, el estudio descubrió que los tuis con uno o dos hashtags reciben un 21% más de participación que aquellos con más de dos hashtags.

3.8 Herramientas

En el desarrollo de este estudio se utilizaron diferentes herramientas para el proceso de recolección, análisis y muestra de los resultados de la información obtenida del corpus de datos, a continuación, se da una breve explicación de que herramientas se usaron para que sirven y donde se ocuparon, posterior a la explicación de las herramientas se nombraran como: Anaconda, MongoDB y Weka.

Anaconda3 versión 2019.07 Python 3.7.3	MongoDB versión 4.2.8	Weka versión 3.9.3
Es un software de distribución	MongoDB es una base de datos de documentos	Sirve para la enseñanza, de la investigación y las aplicaciones

libre y de varios lenguajes de programación como Python, R etc., utilizado para ciencia de datos y aprendizaje automático y muchas cosas más (Anaconda, 2021).	ofrece una gran escalabilidad y flexibilidad, y un modelo de consultas e indexación avanzado. (MongoDB, 2021)	industriales, contiene una gran cantidad de herramientas integradas para tareas estándar de aprendizaje automático (Weka, 2021).
Fase de selección.	Fase de selección.	Fase de minería de datos y evaluación.

Tabla 3-2. Herramientas usadas para el estudio de este proyecto.

Así como describe la Tabla 3-2 estas herramientas permitieron hacer los diferentes experimentos con las colecciones de datos obtenidas de Twitter y obtener los diferentes resultados.

3.9 Síntesis

En este capítulo se presentan los principales fundamentos teóricos de las fases del proceso KDD para analizar textos, el concepto de sarcasmo y los tipos que existen, además, se presentan algunas APIs de desarrollo para extraer tuits de la red social Twitter y conceptos relevantes para la comprensión de tuits y sus componentes.

Capítulo 4

4 Marco Metodológico

En este capítulo se presentan los pasos metodológicos a seguir para la detección de sarcasmo en textos cortos, así como los resultados experimentales donde se calculan métricas de evaluación de algunos algoritmos de clasificación.

4.1 Caso de estudio

Actualmente el mundo se encuentra enfrentando una pandemia por el coronavirus que “son una familia de virus que causan enfermedades desde el resfriado común hasta enfermedades respiratorias más graves y que circulan entre humanos y animales” (Gobierno de México , 2020) dicha pandemia ha hecho que todo el mundo tome las medidas de prevención necesarias para tratar de contener el virus y hacer todo lo posible para que su propagación se detenga, lo que ha llevado a la sociedad a hacer confinamientos en muchos lugares haciendo que casi todas las actividades sean desde casa por lo que ha provocado un cambio radical emocional y físicamente en todos a lo que lleva a muchos a buscar diferentes formas de entretenimiento, pasar el tiempo e interactuar con otras personas, pero lo principal que se ha notado y por diferentes razones ha hecho que las personas hagan más uso del Internet en específico de las redes sociales, puesto que desde que inicio la pandemia el incremento del uso de ellas ha sido muy notable.

Como se ha mencionado en el punto anterior, la razón de este estudio se enfoca en las redes sociales ya que al estar encerrados y por motivos de la pandemia las

reacciones del país en redes sociales ante dicha situación no quedo libre de sufrir sarcasmo en forma de ciberbullying ya que por medio de ellas en específico de Twitter se ha generado una ola de opiniones y controversias, a lo que se realizara una análisis para que se comprenda cómo efectúan el sarcasmo los usuarios de Twitter, motivo por el cual las palabras y utilizando el hashtag descrito en el apartado 3.7, se realizó la recolección del corpus de acuerdo a: #COVID-19 y #sarcasmo y #México puesto que la recolección son tuits en español México.

4.2 Metodología

La Figura 4-1 presenta los pasos metodológicos a seguir para dar solución al problema propuesto.




Figura 4-1.Pasos metodológicos para la detección de sarcasmo en tuits.

A continuación, se desarrolla cada fase dando solución a la detección de sarcasmo en textos cortos obtenidos de Twitter.

4.2.1 Recolección de datos

Para la construcción del corpus (colección de tuits), se solicita el acceso a las APIs de desarrollador que proporciona la plataforma Twitter Developer donde se lleva a cabo la solicitud de permisos para acceder a los datos de Twitter mediante un token de acceso único. Posteriormente, se seleccionan las siguientes APIs: Search Tweets y Stream Tweets in real-time. Para realizar la conexión a Twitter se utiliza un programa implementado en el lenguaje de programación Python para realizar la

extracción de tuits. La recolección de tuits se realiza de dos formas que se describen a continuación:

- **Mediante API y almacenamiento manual**

El corpus tuits utiliza el API search tweets y el código utilizado para la conexión se muestra en la Figura 4-2. Los parámetros necesarios para la conexión son: token de acceso, el API seleccionada, la forma de búsqueda mediante palabras, ruta de almacenamiento y formato de archivo .txt donde se almacena el tuit.

```
import io
import os
import tweepy
import json
auth = tweepy.OAuthHandler(consumer_key, consumer_secret)
auth.set_access_token(access_token, access_token_secret)
api = tweepy.API(auth,
                 wait_on_rate_limit=True,
                 wait_on_rate_limit_notify=True)
i = 33
for tweet in tweepy.Cursor(api.search, q="#sarcasmo #COVID19", tweet_mode="extended").items(3):
    print (json.dumps(tweet._json, indent=4))
    i = i + 1
    print (i)
    nombre = str(i) + ".txt"
    with open("/Users/Adriana/Desktop/NuevosTweets/" + nombre,"w", encoding="utf-8") as f:
        f.write(str((json.dumps(tweet._json, indent=4))))
    f.close()
```

Figura 4-2. Código Python empleado para la conexión con Twitter.

Para la construcción del corpus muestra 1, los tuits son manipulados manualmente y son organizados de acuerdo con 5 palabras clave para su búsqueda como se observa en la Tabla 4-1. El número de tuits que se recolectaron en un periodo de 7 días en un horario de las 8:00 pm a 10 pm dado que la recolección se realiza

conforme a los tuits publicados durante el día, el número de tuits es diferente para cada palabra utilizada ya que los tuits que publica un usuario varían mucho su redacción. Para la recolección se utilizan los términos juntos, pero también se consideran palabras en diferentes posiciones e incluso en algunas se agrega el símbolo de hashtag para dar una mejor búsqueda por este filtro de palabras.

No.	Palabras para recolección	No. de tuits
1	#coronavirus sarcasmo	366
2	#coronavirus sarcasmo México	35
3	Coronavirus, #sarcasmo México, México #coronavirus, #sarcasmo	229
4	COVID-19 sarcasmo México	32
5	#sarcasmo, #COVID19	41

Tabla 4-1. Recolección de tuits de acuerdo con las palabras usadas.

Para el corpus muestra número 1 se recolectaron un total de 693 tuits utilizando la API Search Tweets y haciendo el almacenamiento de manera manual.

- **Mediante API y almacenamiento en Base de Datos**

Para la recolección del corpus de tuits muestra-2 se utilizan dos: APIs, Search Tweets y Stream Tweets in real-time. El código utilizado para la conexión es el mismo de la Figura 4-2 pero se agregan algunas líneas adicionales para permitir una conexión a una base de datos que se muestran en la Tabla 4-2 usando la herramienta de Mongo DB (ver Figura 3-2). Se configuran 4 parámetros para lograr una conexión exitosa: a) el parámetro para inicializar el cliente de Mongo DB, b) la dirección IP del equipo con que se conecta para obtener los datos, c) el nombre de

la base de datos creada con la herramienta de Mogo DB y d) el nombre de la colección dentro de la base de datos donde se realiza la carga de tweets. El resto del código donde se visualiza como se usaron ambas APIs se muestra en la sección de anexos. Las variables obtenidas son: id del tweet, tweet y fecha de creación.

```

cliente = MongoClient()

cliente = MongoClient('127.0.0.1', 27017)

bd= cliente.Twitter

tweets = bd.tweets

```

Tabla 4-2. Conexión a Mongo DB.

Para la búsqueda de estos tuits se utilizan 4 palabras relacionadas con el tema de coronavirus para ambas APIs: Coronavirus, #COVID-19, COVID-19 México, coronavirus México. La Tabla 4-3 muestra el total de tuits recolectados para la muestra 1 y muestra 2 del corpus empleando el modo de recolección manual y automático respectivamente y distintas APIs.

Corpus	Modo de recolección	Total de tweets	API para la recolección
Tweets muestra 1	Manual	693	API Search Tweets
Tweets muestra 2	Automática	233	APIs Search Tweets y Stream Tweets in real-time

Tabla 4-3. Recolección de tuits usando dos modos de recolección y distintas APIs.

4.2.2 Pre procesamiento

El pre procesamiento de datos del corpus consiste en tres pasos: selección de datos del tuit, limpieza y transformación de datos.

4.2.3 Selección de datos del tuit

En la Tabla 4-4 se observa una muestra de todas las variables que devuelve un tuit y que son seleccionadas con base en la información que trae consigo, estas son: id, text, entities y referenced_tweets.

Id	Text	Entities	Referenced_tweets
Identificador único del tweet solicitado.	El texto UTF-8 real del tweet, se devuelve el texto junto a emoticonos y todo lo que escribe un usuario en un tweet.	Entidades que se han analizado del texto del Tweet, como hashtags, links, menciones entre otras.	Una lista de Tweets a los que se refiere este Tweet. Por ejemplo, si el Tweet principal es un Retweet, un Retweet con comentario (también conocido como Tweet citado) o una Respuesta, incluirá el Tweet relacionado al que hace referencia su padre.

Tabla 4-4. Variables de un tuit (Twitter, 2019).

Para realizar el pre procesamiento se utiliza la herramienta Microsoft Excel de la paquetería de Office. Esta fase se aplica tanto al corpus de datos de tuits de la muestra-1 como a los tuits muestra-2. Para la recopilación de información se obtiene la siguiente lista de variables:

- id
- text

- menciones @
- hashtags
- enlaces
- emoticonos
- cantidad de retweets
- referenced_tweets

Los datos recolectados de Twitter se organizaron y separaron en 7 columnas que indican cada una de las variables de la lista anterior y cada fila corresponde a cada tuit con sus respectivos datos como muestran las Figuras 4.3 y 4.4.

_id	Texto del tweet	Menciones(@)	Hashtags
5f09f084165a0e3c47cee8ea	Es que como le dio ... no puede trabajar.. es sarcasmo. De todos modos nunca ha hecho nada el alcalde	@MorganaleFay_ @AcProcoyoacan @manuelnegrete @Alcaldia_Coy @manuelnegrete22	#coronavirus
5f09f0fe3aae28cbe216cd8d			#meme #humor #sarcasmo #yomequedoencasa #coronavirus #cuarentena #toquedequeda #quedateencasa #covid_19 #mujeres #frases
5f09faf8c88aed7876ae3856	En Gutierrez tambien hay Asi dizque se protege en la a los miles de trabajadores de ese lugar... "Bien por los chiapanecos". [nótese el sarcasmo], según dicen que con esa medida todos están "protegidos".		#Tuxtla #Chiapas #coronavirus #COVID19 #TorreChiapas #CPM
5f09fc0fb9b803c8ba1d669b	O sea que después, con el pretexto del , te van a llevar al gulag (o mejor dicho, a un aislamiento por nótese mi sarcasmo).		#COVID19Uruguay #Coronavirus
5f0a0d9fa1d4f64121c47a9a	Es que se lo ponen mug fácil, joder....		#Coronavirus #COVID-19 #poesia #GobiernoDimision #GobiernoMiserable #Desescalada #DesescaladaResponsable #DesescaladaMadrid #humor #parentalrotativas #ironia #SatiraSurrealista #satira #sarcasmo

Figura 4-3. Atributos de tuits separados.

Enlaces (Link)	Emoticonos	Cuantos retweets
https://t.co/IM3PIs79ii		
https://t.co/kPqYm0lSv	💎💎💎	11
https://t.co/2RxVe2qL9		
https://t.co/kLLTi01010		

Figura 4-4. Atributos de tuits separados.

4.2.4 Limpieza de datos

El pre procesamiento continúa con la limpieza de los datos, se seleccionó solo la columna de menciones, hashtags y emoticonos ya que se determina que son las más significativas; para la columna de menciones se realiza una separación de esas menciones a través del símbolo de @. La información que se proporciona es el número de menciones hechas y el nombre de los usuarios dentro del tuit escrito por el usuario, además, el id indica de que tuit se hace referencia. Tomando en cuenta el id que identifica al tuit se aprecian las menciones utilizadas por ese tuit. Cada celda es una mención diferente y cada fila es un tuit, los tuits con filas vacías denotan que no realizan ninguna mención como se muestra la Figura 4-5.

_id	Mencion 1	Mencion 2	Mencion 3	Mencion 4	Mencion 5
5f09f084165a0e3c47cee8ea	MorganaleFay_	AcProcoyoacan	manuelnegrete	Alcaldia_Co	manuelnegrete22
5f09f0fe3aae28cbe216cd8d					
5f09faf8c88aed7876ae3856					
5f09fc0fb9b803c8ba1d669b					
5f0a0d9fa1d4f64121c47a9a					
5f0a0da5b2e557778fb6d6cf					
5f0a0dbba48556d755ab966f	oyecomovapart2	DeptSaludPR	wandavazquez		
5f0a14bc6cb9b08fd8161fe					
5f0a14c81740ec8b6408efa3	caanmichelena	Lenin			
5f0a152aa3fa9e0768cddd72					
5f0a199b928c4eb6b190ab85					
5f0a19a18cb391e26c1e24be					
5f0a1a54425e690649ddce8c					
5f0a1e5737db1ab123b0a3a9	MonicaFradeok	Kicillofok	alferdez	FrenteDeTods	
5f0a1e5d99822ee277f30cd5	cuberosmiguel	alferdez	CulturaNacionAR	sanmihanovich	Pedro_Aznar

Figura 4-5. Separación de menciones de los tuits.

Para la columna de emoticonos se elabora una tabla con el significado de cada emoticono encontrado. Los emoticonos encontrados son: símbolo del hombre, información, flecha hacia la derecha, símbolo de la mujer, surtidor de gasolina, la carcajada, carita con la mano sobre la boca, emoji de la sonrisa, carita sonriente de ojos cerrados, cara sacando la lengua con guiño, flecha curva hacia arriba, emoji feliz, face palm, carita con los ojos en blanco, puño levantado, índice de revés apuntando a la derecha, carita mostrando los dientes sin emoción, carita con gafas de sol, carita sugerente, índice al revés apuntando hacia la izquierda, pulgar arriba, carita volteada y risa con lágrimas de alegría.

El total de emoticonos diferentes son 23 y de acuerdo con el id solo 19 tuits se encontraron con emoticono, lo que representa el 11.59% del total de tuits. Esto indicando que el otro 88.41% de los tuits no tiene emoticonos y por consiguiente no se considera que haya una influencia al momento de realizar la clasificación para detección de sarcasmo en tuits.

En la columna de hashtags se realiza una separación de los datos usando el símbolo # donde en cada uno de ellos y de manera manual se colocan en diferentes colores las palabras que se consideraron como sarcasmo y también la que hablan del coronavirus para diferenciar los datos repetidos. Se hizo el conteo de las palabras para conocer el hashtag más usado y se determinó que el top 6 de las palabras más usadas son:

- sarcasmo
- COVID-19
- coronavirus
- humor
- ironía
- cuarentena

Las palabras están ordenadas de la más repetida que es sarcasmo a la menos repetida que es cuarentena. No obstante, se observó que la palabra COVID-19 y coronavirus al tener el mismo significado se homogeneizaron. Este mismo procedimiento se aplica a las demás palabras que compartan el mismo significado, donde, después de la limpieza de palabras quitando mayúsculas, acentos y símbolos especiales. Por ello, se obtienen las siguientes palabras: COVID19, coronavirus, ironía, humor, class, cuarentena, meme, qudateencasa, gobiernodimision, elalto, indigno, comic.

4.2.5 Transformación

Una vez realizada la limpieza se continua con la transformación de datos y se realiza la construcción de una matriz de forma tal que cada columna es un hashtag tomado de la lista de hashtags homogeneizados. Para cada fila se indica un tuit identificado por su id en la primera columna. Se realiza el llenado de la información de manera manual donde los valores “1” indican que existe ese hashtag en el tuit y un “0” indica que lo contrario.

La selección de una clase se hace con base en el conteo del top 6 de palabras seleccionando el más usado que es “sarcasmo” correspondiente a la clase de la matriz que se coloca al final de las columnas. Al generar la matriz se obtienen los datos de la Figura 4-6; de esta manera se realiza una matriz que solo contiene emoticonos.

_id	covid19	covid_19	covid__19	mueveteenbic	coronaviru	feminicidi	francia	sosnicaragua
5f09f084165a0e3c47cee8ea	0	0	0	0	1	0	0	0
5f09f0fe3aae28cbe216cd8d	0	1	0	0	1	0	0	0
5f09faf8c88aed7876ae3856	1	0	0	0	1	0	0	0
5f09fc0fb9b803c8ba1d669b	0	0	0	0	1	0	0	0
5f0a0d9fa1d4f64121c47a9a	0	0	0	0	1	0	0	0
5f0a0da5b2e55778fb6d6cf	0	0	0	0	1	0	0	0
5f0a0dbba48556d755ab966f	0	0	0	0	1	0	0	0
5f0a14bc6cb9b08fdd8161fe	1	0	0	0	1	0	0	0
5f0a14c81740ec8b6408efa3	0	0	0	0	1	0	0	0
5f0a152aa3fa9e0768cddd72	0	0	0	0	1	0	0	0
5f0a199b928c4eb6b190ab85	0	1	0	0	1	0	0	0
5f0a19a18cb391e26c1e24be	1	0	0	0	1	0	0	0
5f0a1a54425e690649ddce8c	0	0	0	0	1	0	0	0
5f0a1e5737db1ab123b0a3a9	0	0	0	0	0	0	0	0
5f0a1e5d99822ee277f30cd5	0	0	0	0	0	0	0	0
5f0a1e661e86d06a84b518d9	0	0	0	0	0	0	0	0
5f0a1e6e97a29a6466411fad	0	0	0	0	0	0	0	0
5f0a204c2b5c4f0ac0f6a14b	0	0	0	0	0	0	0	0
5f0a209d96d9fee47e986a2b	0	0	0	0	1	0	0	0
5f0a269cd9b94f55afefda23	0	0	0	0	1	0	0	0
5f0a26c5384440683e0f7107	0	0	0	0	0	0	0	0

Figura 4-6. Matriz de hashtags.

Finalmente, después de haber realizado la selección, limpieza de datos y transformación de datos en una matriz. El corpus de tuits muestra-1 se reduce de 693 tuits a 164 tuits y en el corpus tuits muestra-2 paso de 233 tuits a 90 tuits esto de acuerdo con lo aplicado en el punto anterior, por lo tanto, se tienen 164 tuits con sarcasmo y 90 tuits sin sarcasmo como lo indica la Tabla 4-5.

Tuits muestra-1	Tuits muestra-2
164 tuits	90 tuits

Tabla 4-5. Tuits procesados.

4.2.6 Detección de sarcasmo y evaluación

Para realizar la detección de sarcasmo se realizan dos experimentos donde se varían las variables seleccionadas de las matrices utilizando el modelo vectorial en los experimentos donde se colocan 1 y 0 en el lugar donde los 1 son los hashtags repetidos de acuerdo con cada tuit y los ceros para completar la matriz. Para la clasificación de tuits se emplea la herramienta de minería de datos Weka y se prueban 4 algoritmos: J48, Naive Bayes, Random Forest, SVM. Las clases consideradas son textos con y sin sarcasmo.

4.2.7 Experimento 1

Para el primer experimento se generan 3 matrices: una contiene los hashtags y emoticonos, además del ID del tuit otra solo tiene los hashtags con el ID del tuit y la otra con Emoticonos 26 y la clase sarcasmo además del ID del tuit. Se considera

una muestra de los 164 tuits recolectados a partir de la selección de tres matrices distintas que se resumen en la Tabla 4-6.

Experimento 1	Conjunto de datos	No. Tuits	Atributos
Matriz 1	Muestra 1	164	hashtags y emoticonos 167
Matriz 2	Muestra 1	164	Hashtags 141
Matriz 3	Muestra 1	164	Emoticonos 26 y la clase sarcasmo

Tabla 4-6. Experimento 1 variando las columnas de la matriz.

Después de la fase de pre procesamiento se obtiene una matriz para el experimento 1 con las características de la matriz 1 con hashtags y emoticonos. El archivo es convertido al formato csv y seguidamente se carga al programa Weka. Se elimina el ID junto a 15 columnas que solo tienen como hashtag letras y fechas. Se aplican tres algoritmos para hacer la clasificación de tuits y se calcula la medida F (F-Measure) para evaluar el desempeño del modelo. La Tabla 4-7 muestra los valores de la F-Measure para tres algoritmos de clasificación del experimento 1 para la matriz 1 que se calculan al clasificar nuevos tuits.

Random Forest	Naive Bayes	J48
0.864	0.748	0.864

Tabla 4-7. Resultados de F-Measure usando Naive Bayes para el experimento

Para el experimento 1 de la matriz 2 solo con hashtags se eliminan los 22 emoticonos y quedan solo 141 hashtags. El archivo es convertido a la extensión csv

y se prueba con los algoritmos de clasificación que se muestran en la Tabla 4-8. El algoritmo Random Forest presenta mejores resultados que los demás algoritmos con una F-measure de 0.864.

Random Forest	Naive Bayes	J48	LibSVM
0.864	0.754	0.863	0.517

Tabla 4-8. Resultados de F-Measure usando Naive Bayes para el experimento 1.

Para el experimento 1 empleando la matriz 3 con los emoticonos y la clase sarcasmo se encuentra que al aplicar los algoritmos Random Forest, J48 y LibSVM no arrojaron resultados, mientras que el algoritmo NaiveBayes muestra un resultado en la F-Measure de 0.488 para clasificar nuevos tuits.

4.2.8 Experimento 2

El experimento dos se realiza a partir del segundo corpus en el que dando el mismo tratamiento de datos se une la matriz del primer corpus de datos con la matriz del segundo corpus de datos para generar una única matriz. La Tabla 4-9 muestra dos experimentos que utilizan los dos conjuntos de datos muestra 1 y 2 la única diferencia es que la matriz 1 tiene 248 hashtags y la matriz 2 tiene 3 hashtags. De la muestra 2 de 233 tuits se reducen a 99 tuits una vez que pasan por el mismo proceso que la primera muestra de tuits recolectados.

Experimento 1	Conjunto de datos	No. tuits	Matriz
Matriz 1	Muestra 1 y 2 de recolección de datos	160	Hashtags 248

Matriz 2	Muestra 1 y 2 de la recolección de datos	160	Hashtags 3
----------	--	-----	------------

Tabla 4-9. Experimento 2 a partir de segundo corpus y solo con hashtags.

Con este experimento se puede mostrar la efectividad de los algoritmos para clasificar tuits como sarcástico o no sarcástico. Para ello, se calcula una matriz con los primeros datos donde la clase “1” indica un tuit con sarcasmo y la clase “0” indica que es un tuit sin sarcasmo. En total se tiene 258 hashtags que se convierten en un archivo con formato .csv y son procesados con la herramienta weka. Los datos son probados con los mismos algoritmos que el experimento 1 y los resultados de la F-Measure son mostrados en la Tabla 4-10. Como se puede observar, el algoritmo Random Forest presenta el mejor resultado con un valor de 0.780 para clasificar nuevos tuits.

Random Forest	Naive Bayes	J48
0.780	0.751	0.700

Tabla 4-10. Resultados de F-Measure usando diferentes modelos para el experimento 2.

Para el experimento de la matriz 2 de la Tabla 4-9 se redujeron la matriz a solo 3 hashtags que son: covid19, humor y la clase definida de sarcasmo con ello se probó la efectividad de los algoritmos de clasificación en la Tabla 4-11 se muestran los resultados en donde se aplicaron los 4 algoritmos los cuales arrojaron 0.830 para Random Forest Naive Bayes, LibSVM y 0.817 en J48 muy cercanos al 1 lo que indico una buena clasificación de los datos en sarcasmo y sin sarcasmo.

Random Forest	Naive Bayes	J48	LibSVM
---------------	-------------	-----	--------

0.830	0.830	0.817	0.830
-------	-------	-------	-------

Tabla 4-11. Resultados F-Mesure usando diferentes modelos para el experimento2.

4.3 Análisis de resultados

En el experimento 1 en la Tabla 4-6 en las matrices 1 y 2 se obtiene para ambas el resultado F-Measure de 0.864 en el algoritmo Random Forest, en Naive Bayes la matriz 2 mejoro en su clasificación ya que obtuvo un resultado de 0.754 mientras que la matriz 1 obtuvo un resultado de 0.748, para el algoritmo J48 en ambas matrices solo hubo una pequeña diferencia puesto que la matriz uno resultó con 0.864 y la matriz 2 0.863 lo que indica que en este algoritmo no influyo la reducción de atributos por último el algoritmo LibSVM en la matriz 1 el algoritmo no permitió realizar la clasificación por lo que no se indica ningún resultado a diferencia de la matriz 2 que tuvo un resultado de 0.517 de clasificación.

Para la matriz 3 de solo emoticonos los resultados que mostraron los algoritmos tuvieron poca precisión en la clasificación solo el algoritmo NaiveBayes muestra un resultado en la F-Measure de 0.488 para clasificar nuevos tuits. Con dichos resultados se demuestra que los hashtags por sí solos generan mejores resultados en la clasificación de sarcasmo a comparación de los emoticonos los cuales tienen poca influencia en la detección de sarcasmo para este estudio.

En el experimento 2 la Tabla 4-9 en las matrices 1 y 2 utilizaron ambos conjuntos de datos descritos en el apartado 4.2.2 para la matriz 1 los resultados de F-Measure se muestran muy acertados en la clasificación para los algoritmos Random Forest con 0.780 seguido Naive Bayes con 0.751 y por último J48 con una métrica de

Por otra parte, se realizó el conteo de los hashtags que tuvieron más repeticiones para ello se graficaron los datos resultantes quedando en primer lugar el hashtag sarcasmo con 60 repeticiones.

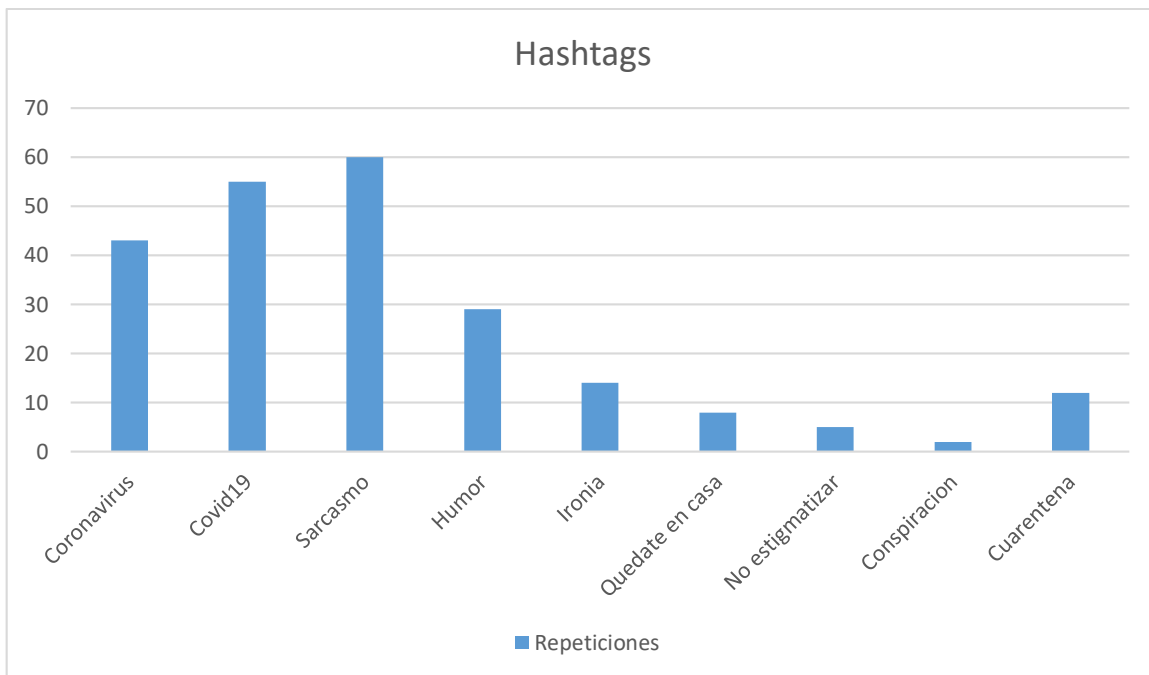


Figura 4-8. Hashtags repetidos.

4.4 Síntesis

En este capítulo se presentaron los experimentos realizados para el desarrollo de la tesis, se aplicaron los pasos del modelo KDD: recolección de tuits, preprocesamiento de los datos que incluye limpieza y transformación de tuits, aplicación de los algoritmos de minería de datos y el análisis de los resultados.

Capítulo 5

5 Conclusiones y trabajo a futuro

En este capítulo se presentan los resultados del trabajo de tesis, así como el trabajo propuesto a futuro.

5.1 Conclusiones

Los resultados obtenidos en este trabajo destacan que los emoticonos no demuestran mucha influencia con el texto de un tuit dado que al introducirlo al algoritmo de clasificación no mejoraron los resultados, por el contrario, se reduce certeza en la clasificación. Por otro lado, los hashtags si permiten realizar una clasificación para determinar si un tuit tiene o no sarcasmo. Durante la pandemia del COVID-19 los internautas incrementaron el uso de las diferentes aplicaciones que ofrece el Internet, específicamente, la red social Twitter.

Los objetivos perseguidos en este trabajo de tesis fueron logrados, retomado el objetivo general se pudo demostrar que el sarcasmo puede ser detectado en textos cortos analizando sus componentes tales como los hashtags y los emoticonos, aunque los emoticonos no arrojaron buenos resultados en la clasificación de tuits con sarcasmo, los hashtags son de utilidad para su detección, además en el análisis se observó que los usuarios demuestran sarcasmo ante situaciones como la pandemia del COVID-19. Se identificó que el sarcasmo utilizado no es con fines de cyberbullyng, más bien con fines de humor ante esta situación, ya que las palabras ofensivas encontradas fueron muy pocas.

En cuanto a los objetivos particulares se dio cumplimiento a todos ya que se recolectaron tuits en español de la plataforma Twitter Developer a través de la API de la plataforma; se realizó el procesamiento de datos a través de la identificación de palabras, emoticonos, menciones, hashtag por medio de técnicas de análisis lingüístico. Se seleccionaron los algoritmos Naive Bayes, Random Forest y J48 para la clasificación de los tuits, ya que estos algoritmos dieron mejores resultados y son un referente en el estado del arte. Finalmente se evaluaron y analizaron los resultados de la clasificación del sarcasmo a través de la métrica F-Measure obteniendo en la mayoría de los casos resultados superiores al 80% de tuits clasificados correctamente.

Por consiguiente y de acuerdo a los resultados obtenidos los algoritmos que mejor clasificaron los tuits son: en el experimento 1 Random forest con una precisión de 0.864 y J48 con una precisión de 0.864 y para el experimento 2 el algoritmo Random forest con una precisión de 0.830, para concluir las palabras que ayudaron más a mejorar el resultado en la clasificación de tuits con sarcasmo son: covid19 y humor anudado a esto la clase sarcasmo.

5.2 Trabajo a futuro

Como trabajo a futuro se proponen los siguientes puntos.

- Utilizar un modelo de representación de tuits con más características para mejorar la precisión del modelo de clasificación utilizando el contenido completo de los tuits que permita analizar a detalle la forma en que los usuarios se expresan con sarcasmo en la red social de Twitter.

- Probar otros algoritmos de clasificación que puedan mejorar el desempeño de la clasificación.
- Generar una recolección de tuits para tener un conjunto mayor de aprendizaje, así como para poder comparar la percepción de los usuarios de redes sociales en distintas etapas de la pandemia de COVID-19. Este trabajo se realizó al inicio de la pandemia, sin embargo, es importante analizar cómo han cambiado los tuits de sarcasmo conforme la pandemia avanzó en el tiempo y tuvo efectos más devastadores en la sociedad, economía y comportamiento social.

6 Anexo

```
import tweepy

import requests

import codecs

from pymongo import MongoClient

cliente = MongoClient()#Inicializarobjeto

cliente = MongoClient('127.0.0.1', 27017)

bd= cliente.Twitter#SeleccionarSchema

tweets = bd.tweets#SeleccionarColeccion

auth = tweepy.OAuthHandler(consumer_key, consumer_secret)

auth.set_access_token(access_token, access_token_secret)

api = tweepy.API(auth,

                 wait_on_rate_limit=True,

                 wait_on_rate_limit_notify=True;

for tweet in tweepy.Cursor(api.search, q="#COVID_19 #Mexico", tweet_mode="extended").items(15):

    print (json.dumps(tweet._json, indent=4))

    tweets.insert_one(tweet._json)
```

Figura 6-1.Código de conexión.

```
import sys

import tweepy

import requests

import codecs

from pymongo import MongoClient

cliente = MongoClient()

cliente = MongoClient('127.0.0.1', 27017)
```

```

bd= cliente.Twitter

tweets = bd.tweets

api = tweepy.API(auth, wait_on_rate_limit=True, wait_on_rate_limit_notify=True)

class TweetsListener(tweepy.StreamListener):

    def on_connect(self):

        print("Estoy conectado!")

    def on_status(self, status):

        print(status.text)

    def on_error(self, status_code):

        print("Error", status_code)

    def on_status(self, status):

        if not hasattr(status, 'retweeted_status'):

            print (status.text.encode('utf-8'))

            tweet = {

                "idt": str(status.id),

                "tweet": status.text.encode('utf-8'),

                "fecha_creacion": status.created_at,

                "sentimiento": ""

            };

            tweets.insert_one(tweet)#almacenar tweet

stream = TweetsListener()

streamingApi = tweepy.Stream(auth=api.auth, listener=stream)

streamingApi.filter(

    track=["#COVID19 Mexico "]

)

```

Figura 6-2. Código de conexión.

7 Bibliografía

- Joshi, A., Bhattacharyya, P., & Carman, M. (2018). *Investigations in Computational Sarcasm*. Mumbai Maharashtra India: Springer.
- Mosquera, R., Parra Osorio, L., & Castrillón, O. (2016). Metodología para la Predicción del Grado de Riesgo. *Información Tecnológica*, 259-272.
- Osman, M. (2018). *Estadísticas Impresionantes y Datos Importantes de Twitter*. Recuperado el 2020, de Kinsta: <https://kinsta.com/es/blog/estadisticas-twitter/>
- A, K., & D, T. (2020). Sarcasm Identification and Detection in Conversation. *Proceedings of the Second Workshop on Figurative Language Processing* (págs. 72-76). Tamilnadu, India: Association for Computational Linguistics.
- A.Saravananaraj, I. S. (2019). Automatic detection of cyberbullying from Twitter. *International Journal of Computer Science and Information Technology & Security (IJCSITS)*, 6. Recuperado el 2020
- Aditya Joshi, P. B. (2017). Automatic Sarcasm Detection: A Survey., (pág. 22).
- Amat Rodrigo, J. (2015). *Arboles de decision, Random Forest, Gradient Boosting y C5.0*. Recuperado el 2020, de Cienciadedatos: https://www.cienciadedatos.net/documentos/33_arboles_de_prediccion_bagging_random_forest_boosting#Random_Forest
- Amat Rodrigo, J. (2015). *Cienciadedatos*. Recuperado el 2020, de Máquinas de Vector Soporte (Support Vector Machines, SVMs): https://www.cienciadedatos.net/documentos/34_maquinas_de_vector_soporte_support_vector_machines#Hiperplano_y_Maximal_Margin_Classifier
- Anaconda. (2021). Recuperado el 2021, de Anaconda | Individual Edition: <https://www.anaconda.com/products/individual>
- Arthur Patch, J. (2015). *Detecting bullying on twitter using emotion lexicons*. ATENAS, GEORGIA: Universidad de Georgia.

- Asociación de internet MX.* (2021). Recuperado el 2020, de Estudio sobre los Hábitos de los Usuarios de Internet en México 2020: <https://irp-cdn.multiscreensite.com/81280eda/files/uploaded/16%20Estudio%20sobre%20los%20Ha%CC%81bitos%20de%20los%20Usuarios%20de%20Internet%20en%20Me%CC%81xico%202020%20versio%CC%81n%20pu%CC%81blica.pdf>
- Bamman , D., & A. Smith, N. (2015). *Contextualized Sarcasm Detection on Twitter*. En la Novena Conferencia Internacional AAAI sobre Web y Redes Sociales.
- Chatzakou Despoina, K. N., & Vakali, A. (2017). *Mean Birds: detecting aggression and bullying on twitter*. Universidad Aristóteles de Salónica. Recuperado el 2020, de Mean Birds: Detecting Aggression and Bullying on Twitter: <https://www.researchgate.net/publication/318330507>
- De Francisco Rus, A. (2018). *Construcción de modelos de clasificación automática para la detección de acoso*. Madrid: Universidad Autonoma de Madrid Escuela Politecnica Superior.
- DigitalTroupe Brand Services.* (2015). Recuperado el 2020, de DigitalTroupe: <http://www.digitaltroupe.com/anatomia-de-un-tweet/>
- Garcia, Y. G. (2013). *Algoritmos SVM para problemas sobre big*. Madrid. Recuperado el 2021
- García-González, J., Sánchez-Sánchez, P., Orozco, M., & Obredor, S. (2019). *Formación universitaria*. Recuperado el 2021, de Extracción de Conocimiento para la Predicción y Análisis de los Resultados de la Prueba de Calidad de la Educación Superior en Colombia: https://scielo.conicyt.cl/scielo.php?script=sci_arttext&pid=S0718-50062019000400055
- Glosario.* (2021). Recuperado el 2021, de Twitter: <https://help.twitter.com/es/glossary>
- Gobierno de México .* (2020). Recuperado el 2021, de ¿Qué es el coronavirus?: <https://coronavirus.gob.mx/covid-19/>

- H. John , G., & Langley , P. (1995). *Estimating continuous distributions in Bayesian classifiers | Proceedings of the Eleventh conference on Uncertainty in artificial intelligence.* Recuperado el 2020, de Acm: <https://dl.acm.org/doi/pdf/10.5555/2074158.2074196>
- Hämäläinen, M. (2016). *Reconocimiento automático del sarcasmo.* Helsinki, Finlandia: Universidad de Helsinki.
- Haro, S., Zúñiga, L., Vera Rojas, L., & Villa, A. (2018). *mÉTODOS DE ClasfIcACIÓN EN mINERÍA DE DaTOS mETEOrOIÓgICOs Methods of Classification in Mining of Meteorological Data R esumen A bstract.* Recuperado el 2020, de <http://ceaa.esPOCH.edu.ec:8080/revista.perfiles/Articulos/Perfiles20Art13.pdf>
- INEGI. (2020). *MÓDULO SOBRE CIBERACOSO 2019.* Recuperado el 2021, de MOCIBA 2019: <https://www.inegi.org.mx/contenidos/saladeprensa/boletines/2020/EstSociodemo/MOCIBA-2019.pdf>
- Jasso, G., & Meza, I. (2016). Character and word baselines systems for irony detection in Spanish short texts. *Procesamiento del Lenguaje Natural*, 56, 41-48.
- Marin Castro, H. (s.f.). *Minería de Datos.* Recuperado el 2021, de <https://www.tampc.cinvestav.mx/~hmarin/Mineria/EC2.pdf>
- Minewiskan. (2018). *Algoritmos de minería de datos (Analysis Services, minería de datos).* Recuperado el 2020, de Microsoft: <https://docs.microsoft.com/es-es/analysis-services/data-mining/data-mining-algorithms-analysis-services-data-mining?view=asallproducts-allversions>
- Miranda, M., & J. G. (2017). *Formación universitaria.* Recuperado el 2021, de Análisis de la Deserción de Estudiantes Universitarios usando Técnicas de Minería de Datos: https://scielo.conicyt.cl/scielo.php?pid=S0718-50062017000300007&script=sci_arttext&tlng=n
- MongoDB. (2021). Recuperado el 2021, de ¿Qué es MongoDB?: <https://www.mongodb.com/es/what-is-mongodb>

Monteiro e Silva, G., Félix F. da Silva, N., & De Souza Dias, M. (2017). *Aplicando técnicas de aprendizaje de máquina para detección automática de bullying no twitter*. Goiânia, Goiás, Brasil: Escuela Regional de Informática Goiás. Recuperado el 2020, de Aplicando técnicas de aprendizaje de máquina para detección automática de bullying no Twitter: https://www.researchgate.net/publication/321419926_Aplicando_tecnicas_de_aprendizado_de_maquina_para_deteccao_automatica_de_bullying_no_Twitter

Olivier Peralta, E. (2017). *Hashtag: Para qué Sirven y Cómo Usarlos Correctamente*. Recuperado el 2020, de Blog de Marketing: <https://www.genwords.com/blog/hashtag#:~:text=Los%20hashtag%20est%C3%A1n%20precedidos%20por,usuarios%20interesados%20en%20el%20tema.>

Oscar Nigro, H., Xodo, D., Corti, G., & Terren, D. (s.f.). *KDD (Knowledge Discovery in Databases): Un proceso centrado en el usuario*. Obtenido de http://sedici.unlp.edu.ar/bitstream/handle/10915/21220/Documento_completo.pdf?sequence=1

Pang-Ning, T. M. (2006). *Introduction to data mining*,. in Library of Congress.

Pérez López, C., & Santín González, D. (2007). *Minería de datos. Técnicas y herramientas*. Paraninfo. Recuperado el 2020, de Google Books: https://books.google.com.mx/books?id=wz-D_8uPFCEC&pg=PA11&dq=proceso+KDD&hl=es-419&sa=X&ved=2ahUKEwiJsQD16JvtAhWbHc0KHR6VDO0Q6AEwAAnoECAYQAg#v=onepage&q=proceso%20KDD&f=false

Petersel, B., & Schindler, E. (2012). *The Complete Idiot's Guide to Twitter Marketing*. USA: ALPHA Penguin Group (USA) Inc.

Rajadesingan, A., Zafarani, R., & Liu, H. (2015). Detección de sarcasmo en twitter: un enfoque de modelado de comportamiento. *En Actas de la octava conferencia internacional de ACM sobre búsqueda web y minería de datos* (págs. 97-106). Computer Science and Engineering Arizona State University.

RapidMine. (2021). Recuperado el 2021, de rRapidMiner | Best Data Science & Machine Learning Platform: <http://rapidminer.com/>

Roman, V. (2019). *Algoritmos Naive Bayes: Fundamentos e Implementación*. Recuperado el 2020, de Medium: <https://medium.com/datos-y-ciencia/algoritmos-naive-bayes-fundamentos-e-implementaci%C3%B3n-4bcb24b307f>

Salinas, A. (2017). *Origen, historia e información completa sobre la red social Twitter*. Recuperado el 2020, de Blog de Marketing Digital y Estrategias de Contenido: <https://mott.marketing/origen-historia-e-informacion-completa-sobre-la-red-social-twitter/#:~:text=La%20red%20social%20Twitter%20fue,hab%C3%ADan%20sido%20colaboradores%20de%20Google.&text=Al%20inicio%2C%20este%20microblogging%20fue,empleados%20de%20la%20c>

Sanchez, H., & Kumar, S. (2020). *ResearchGate*. Recuperado el 2020, de Detección de acoso en Twitter: https://www.researchgate.net/publication/267823748_Twitter_Bullying_Detection

Sanz, E. (2012). *La historia secreta de Twitter*. Recuperado el 2020, de MuyInteresante.es: <https://www.muyinteresante.es/tecnologia/articulo/la-historia-secreta-de-twitter>

Twitter. (2019). Recuperado el 2021, de Tweet object: <https://developer.twitter.com/en/docs/twitter-api/data-dictionary/object-model/tweet>

Twitter Developer. (2020). Recuperado el 2021, de Getting Started with the Twitter API: <https://developer.twitter.com/en/docs/twitter-api/getting-started/guide>

Twitter Help Center. (2020). *Cómo usar los hashtags*. Recuperado el 2020, de Twitter: <https://help.twitter.com/es/using-twitter/how-to-use-hashtags>

Twitter Help Center. (2020). *Twitter*. Recuperado el 2021, de Cómo usar los hashtags.

Weka. (2021). Recuperado el 2021, de Weka 3 - Data Mining with Open Source Machine Learning Software in Java: <https://www.cs.waikato.ac.nz/ml/weka/>