



Universidad de Buenos Aires

Facultad de Ciencias Exactas y Naturales
Departamento de Ciencias de la Computación

Identificación de emociones en Twitter durante el proceso electoral de 2022 en Colombia

Tesis presentada para optar por el título de

**Magister de la Universidad de Buenos Aires en
Explotación de Datos y Descubrimiento del
Conocimiento**

por

Juan Jose Iguaran Fernandez

Director: Dr. Juan Manuel Pérez

Codirector: Dr. Germán Rosati

Defendida el 28 de Noviembre del 2023, Buenos Aires, Argentina

AGRADECIMIENTOS

Quiero agradecer a la Maestría por todo el conocimiento y la formación brindada sin los cuales este trabajo no habría sido posible. Agradezco también a mis directores por todo su apoyo, paciencia y mentoría a lo largo de este proceso.

A Luis Felipe Nuñez, cuyas valiosas palabras "Tomate en serio" forjaron mi motivación. A Jaime Diaz, gracias a quien pude iniciar este viaje y estuvo presente de muchas formas. A Carolina Franco cuyo afecto, apoyo y acompañamiento fueron claves durante este proceso, y a Judith Fernandez, la autora de mi vida.

Todos los estados encuentran su origen en la mente. La mente es su fundamento y son creaciones de la mente. Si uno habla o actúa con un pensamiento impuro, entonces el sufrimiento le sigue de la misma manera que la rueda sigue la pezuña del buey...

Todos los estados encuentran su origen en la mente. La mente es su fundamento y son creaciones de la mente. Si uno habla o actúa con un pensamiento puro, entonces la felicidad le sigue como una sombra que jamás le abandona.

—*Dhammapada*

Resumen

El estudio de Twitter como medio para el análisis de fenómenos sociales mediante técnicas de procesamiento del lenguaje natural (NLP) ha generado gran interés en los últimos años debido a la disponibilidad de grandes cantidades de datos en un ambiente relativamente espontáneo. Dentro de estas técnicas, la detección de emociones en el texto es especialmente relevante, ya que permite identificar la respuesta subjetiva de las personas ante los distintos eventos sociales presentados. Los modelos de lenguaje basados en redes neuronales, como los Transformers y específicamente BERT, han reemplazado las técnicas tradicionales de NLP debido a su capacidad para capturar el sentido y las relaciones entre las palabras en el texto. Sin embargo, en español hay pocos estudios de detección de emociones en redes sociales y ninguno que utilice modelos de lenguaje basados en Transformers en un contexto político.

El objetivo del trabajo fue utilizar modelos basados en BERT para detectar emociones en Twitter durante las elecciones presidenciales de Colombia en 2022, etiquetando manualmente un conjunto de tweets y realizando experimentos de clasificación con modelos pre-entrenados en español. Los resultados de predicción de los modelos sirvieron para analizar las respuestas emocionales de los usuarios, asociando los tweets a sectores políticos, así como la variación temporal. Se encontró una mayor presencia de las emociones asco y alegría en los tweets etiquetados manualmente, lo que resultó en un mejor rendimiento de los modelos en tweets etiquetados con estas emociones. Además, el modelo RoBERTuito se destacó en su desempeño en todas las emociones debido a su pre entrenamiento específico para tweets en español. También se observó que los tweets asociados a la derecha expresaba más asco, mientras que aquellos asociados a la izquierda mostraban más alegría, y que los días con eventos

políticos relevantes generaban más etiquetas emocionales.

Palabras Clave: [BERT, NLP, Colombia, Elecciones, Detección de emociones]

Emotion Identification on Twitter During the 2022 Electoral Process in Colombia

Abstract

The study of Twitter as a means for analyzing social phenomena through natural language processing (NLP) techniques has generated great interest in recent years due to the availability of large amounts of data in a relatively spontaneous environment. Within these techniques, emotion detection in text is particularly relevant as it allows for identifying the subjective response of individuals to different social events presented. Language models based on neural networks, such as Transformers and specifically BERT, have replaced traditional NLP techniques due to their ability to capture the meaning and relationships between words in text. However, there are few studies on emotion detection in Spanish social networks and none that use language models based on Transformers in a political context.

The objective of the study was to use BERT-based models to detect emotions on Twitter during the 2022 Colombian presidential elections, manually labeling a set of tweets and conducting classification experiments with pre-trained models in Spanish. The prediction results of the models were used to analyze users' emotional responses, associating tweets with political sectors as well as temporal variation. A higher presence of emotions such as disgust and joy was found in manually labeled tweets, resulting in better model performance on tweets labeled with these emotions. Additionally, the RoBERTuito model stood out in its performance on all emotions due to its specific pre-training for Spanish tweets. It was also observed that tweets associated with the right expressed more disgust, while those associated with the

left showed more joy, and that days with relevant political events generated more emotional labels.

Keywords: [BERT, NLP, Colombia, Elections, Emotion Identification]

Índice general

Índice de figuras	9
Índice de cuadros	11
1. Introducción	1
1.1. Análisis de sentimiento en Twitter en torno a política	1
1.2. Avances técnicos recientes en análisis de sentimiento	2
1.3. Aporte de este trabajo	3
2. Trabajo Previo	6
2.1. Aprendizaje supervisado en la detección de emociones	7
2.2. Redes neuronales para el análisis de texto	8
2.3. Sentimientos y emociones en redes sociales	13

3. Metodología	17
3.1. Datos	17
3.1.1. Recolección y análisis exploratorio de datos	18
3.1.2. Etiquetado	22
3.2. Experimentos de clasificación	32
3.2.1. Modelos preentrenados	33
3.2.2. Entrenamiento de los modelos	33
3.2.3. Evaluación de los modelos	34
4. Resultados	36
4.1. Desempeño de los modelos entrenados	37
4.2. Distribución de emociones por orientación política	39
4.3. Emociones a lo largo del tiempo	42
5. Conclusiones	47
Referencias	50
A. Anexos	57

Índice de figuras

2.1. Arquitectura de los Transformers	10
2.2. Comparación entre mecanismos de redes. Fuentes Jurafsky (2000), Wikipedia contributors (2022)	11
2.3. Arquitectura de BERT. Fuente Devlin, Chang, Lee, y Toutanova (2018)	12
3.1. Porcentaje de Hashtags según la orientación política asignada	21
3.2. Porcentaje de Tweets según la orientación política asignada	21
3.3. Porcentaje de tweets según orientación política a lo largo del tiempo .	22
3.4. Proceso de etiquetado	25
3.5. Interfaz de etiquetado	26
3.6. Índice de correlación entre etiquetadores de las emociones asignadas a los tweets	28
3.7. Matriz de co ocurrencia entre etiquetas asignadas	31

4.1. Matriz de confusión entre etiquetas asignadas y predicciones del algoritmo para el dataset etiquetado	38
4.2. Porcentaje de tweets clasificado según emociones por el algoritmo	40
4.3. Porcentaje de tweets clasificados según emoción por el algoritmo, separado por orientación política del hashtag	41
4.4. Porcentaje diario del total de tweets clasificados en cada emoción a lo largo del tiempo	43
4.5. Porcentaje diario del total de tweets clasificados como Alegría, para cada orientación política	44
4.6. Porcentaje diario del total de tweets clasificados como Miedo, para cada orientación política	44
4.7. Porcentaje diario del total de tweets clasificados como Tristeza, para cada orientación política	45
4.8. Porcentaje diario del total de tweets clasificados como Asco, para cada orientación política	46

Índice de cuadros

3.1. Ejemplos de tweets clasificados	20
3.2. Descripción de las emociones usadas	24
3.3. Cantidad de tweets asignados a cada emoción por etiquetador	27
3.4. Índice de Fleiss Kappa en cada emoción	29
3.5. Ejemplos de tweets clasificados por etiquetador	30
3.6. Cantidad de tweets por cantidad de etiquetas finales asignadas	31
3.7. Ejemplos de tweets con etiquetas múltiples	32
3.8. Descripción de los modelos usados	33
4.1. Métricas de los modelos entrenados	37
4.2. Ejemplos de tweets con divergencias entre etiquetas y clasificaciones	39
A.1. Hashtags	57

Capítulo 1

Introducción

1.1. Análisis de sentimiento en Twitter en torno a política

En el ámbito de la extracción de opiniones en el texto, Twitter ha sido analizado como un medio particularmente interesante para el estudio indirecto de fenómenos sociales. Esto se debe a su capacidad para captar a una gran cantidad de usuarios que discuten sobre una amplia variedad de tópicos, empleando una cantidad limitada de palabras y un estilo propio.

Este enfoque ha sido estudiado en el pasado por O'Connor, Balasubramanyan, Routledge, y Smith (2010), quienes analizaron cómo los textos provenientes de esta plataforma coinciden con otras aproximaciones de la realidad social, como las encuestas de opinión, en relación a eventos de relevancia popular. De manera similar, Tumasjan, Sprenger, Sandner, y Welppe (2010) y S. M. Mohammad, Zhu, Kiritchenko,

y Martin (2015) han utilizado esta red social para identificar las emociones presentes en los tweets relacionados con temas políticos. Cabe resaltar sin embargo que existe cierto sesgo en este tipo de estudios, pues la muestra de la población total que esta disponible en Twitter no es del todo representativa, puesto que supone condiciones como el acceso a Internet que no son universales para toda la población.

No obstante, en el caso del español existen pocos estudios que se centren en la detección de emociones en redes sociales. Hasta ahora no se tiene conocimiento de ningún estudio que haya empleado modelos de lenguaje basados en Transformers con este propósito, especialmente en el contexto político

1.2. Avances técnicos recientes en análisis de sentimiento

El estudio del análisis de sentimientos en general, y de emociones en particular, se ha realizado a través de técnicas tradicionales de NLP, cuyo enfoque se centra en la relación entre los términos y los estados emocionales. Recientemente, se ha avanzado hacia el uso de algoritmos basados en redes neuronales para capturar un sentido más general del texto basado en la relación que existe entre las palabras que lo componen. Inicialmente, para este propósito se utilizaron las RNN (Redes Neuronales Recurrentes), pero debido a su arquitectura, no era posible suministrar grandes cantidades de texto y captar la información contextual, ya que su entrenamiento se volvía demasiado pesado computacionalmente y la información del inicio del texto era difícilmente asociada a la información del final.

En ese contexto, surge una nueva arquitectura conocida como Transformers (Vaswani et al., 2017), que elimina la estructura recurrente. Este modelo utiliza únicamente múltiples capas de auto-atención. Al eliminar los pasos recurrentes, permitió la paralelización del cálculo y poder entrenar la red con grandes volúmenes de texto de manera eficiente. Esto permite captar información del sentido del texto de una manera más compleja y computacionalmente más eficiente.

BERT (Devlin et al., 2018), es un ejemplo de un modelo basado en Transformers que aprende el sentido del lenguaje de manera general a partir del entrenamiento con grandes volúmenes de datos provenientes de internet, como la Wikipedia. Este modelo pre-entrenado luego se utiliza para diversas tareas de procesamiento de lenguaje natural mediante el fine tuning de la última capa de la red, como por ejemplo el análisis de sentimiento. En el caso del español, existen distintos modelos basados en BERT específicamente para este idioma, que han sido entrenados a partir de textos provenientes de datos abiertos como el propuesto por Canete et al. (2020).

1.3. Aporte de este trabajo

El presente trabajo tiene como objetivo el empleo de modelos de lenguaje, específicamente modelos pre entrenados de lenguaje, para detectar emociones presentes en Twitter durante las elecciones presidenciales en Colombia en 2022. Estas consistieron en una primera vuelta celebrada el 29 de mayo y una segunda vuelta celebrada el 19 de junio. Los candidatos de la primera vuelta fueron Gustavo Petro, Rodolfo Hernandez, Federico Gutierrez y Sergio Fajardo. El candidato Gustavo Petro es asociado a la izquierda Colombiana, Rodolo Hernandez es asociado a una derecha no

tradicional, Federico Gutierrez se asocia a la derecha tradicional y Sergio Fajardo se asocia con el centro político. Los ganadores de la primera vuelta fueron Gustavo petro con un 40.34 % y Rodolfo Hernandez con un 28.17 % pasando de este modo a la segunda vuelta. En esta, el ganador fue gustavo con un 50.44 % obteniendo Rodolfo Hernandez un 47.21 % ¹.

Para obtener los datos de entrenamiento, se utilizó una base de datos obtenida a través de la descarga de tweets mediante la API, utilizando hashtags relacionados con el tema de las elecciones, entre el 22 de mayo y el 22 de junio de 2022, período que comprende la primera y segunda vuelta presidencial de las elecciones en Colombia. Estos hashtags y por lo tanto, los tweets relacionados con ellos, fueron asociados por el autor a los sectores políticos de izquierda, derecha o neutro, basándose en el contenido observado en los tweets y en el apoyo o rechazo que estos muestren. A partir de ahí, se procedió a tomar una muestra de 1200 tweets para ser etiquetados manualmente por el autor y los directores, con alguna de las emociones disponibles. Con los tweets etiquetados, se procedió a realizar el fine tuning de varios modelos de lenguaje preentrenados y a evaluar su desempeño para seleccionar el mejor. Este modelo fue utilizado para clasificar toda la base de datos y a partir de esta clasificación, se realizaron agrupaciones que permitieron determinar la respuesta emocional de los tweets asociados a cierto sector político, así como la variación temporal de esta respuesta.

Se observó que las emociones asco y alegría tuvieron una presencia mayor en los tweets etiquetados manualmente con respecto a las emociones tristeza y miedo. Además, usualmente los tweets a los que se les era asignado tristeza o miedo, se les asignaba también asco. Esto provocó un desempeño más pobre con respecto a

¹https://es.wikipedia.org/wiki/Elecciones_presidenciales_de_Colombia_de_2022

asco y alegría. En cuanto a los resultados de clasificación obtenidos por el modelo de mejor desempeño, robertuito, las etiquetas asignadas a los tweets de la base de datos, coincidieron con las respuestas emocionales esperadas en eventos clave durante las elecciones. Se observó además una mayor presencia de la etiqueta alegría en tweets cuya orientación política asignada fue la izquierda y más asco en los tweets a los que se les asignó orientación de derecha. Este fenómeno se explica en parte por el hecho de que el candidato victorioso es de tendencia izquierdista. Ponemos a disposición el conjunto de datos y el modelo para futuras investigaciones sobre emociones en español en diferentes contextos.

Capítulo 2

Trabajo Previo

El presente capítulo aborda los estudios más relevantes hasta la fecha relacionados con la detección de emociones en el texto, los modelos de aprendizaje automático utilizados en dicha tarea y su aplicación en el contexto de las redes sociales.

Se mencionan estudios que se centran en la detección de opiniones negativas o positivas en textos en distintos dominios, como las calificaciones de películas. Se destaca la importancia que ha tenido en este campo contar con una base de términos clasificados según su orientación emocional, lo cual permite realizar análisis automáticos. Además, se explora la evolución hacia el uso de redes neuronales, específicamente modelos basados en la arquitectura Transformer, como BERT, para capturar el sentido y las relaciones entre palabras en el análisis de texto. También se discute la aplicación de estos modelos en español. Por último, se aborda el análisis de sentimientos y emociones en redes sociales como blogs y Twitter, resaltando su utilidad en la comprensión de la percepción pública y en la identificación de estados emocionales en torno a eventos políticos y sociales.

2.1. Aprendizaje supervisado en la detección de emociones

La detección automática de las respuestas internas que las personas reflejan en el texto ante ciertos fenómenos ha sido estudiada con mucho interés. Así lo establecieron Pang, Lee, y Vaithyanathan (2002), quienes destacaron la importancia de desarrollar sistemas capaces de identificar si existe opinión negativa o positiva ante textos que reflejen opiniones subjetivas. Para este propósito, se empleó el dominio de las reseñas en línea de películas, lo que facilita la tarea de construir algoritmos de aprendizaje supervisado, al contar con una clasificación negativa o positiva del texto por parte del usuario. Estos algoritmos buscan entrenar un modelo a partir de ejemplos previamente clasificados, que sea capaz de predecir una variable objetivo dadas unas variables predictoras. En ese sentido, las variables predictoras se construyen a partir del texto, principalmente mediante la elaboración de unigramas, que son elementos individuales del texto, como las palabras, y como variable objetivo se utiliza la clasificación asignada. Por otro lado, Turney (2002) intentó establecer mediante aprendizaje no supervisado si una determinada reseña en línea sobre diversos temas presenta un sentimiento negativo o positivo. Para ello, utiliza el concepto de orientación semántica presentado por Hatzivassiloglou y McKeown (1997) para determinar si una frase tiene una orientación negativa o positiva, y así poder decidir si la reseña en su conjunto es positiva o negativa. En general, la determinación de la orientación negativa o positiva dentro del texto constituye la detección de la polaridad.

Para llevar a cabo la detección automática de los estados emocionales presentes en el texto, ha sido importante contar con un corpus de términos que cuenten con una clasificación previa. En este sentido, Strapparava, Valitutti, et al. (2004) realizaron

una anotación manual de los estados emocionales usando las categorías desarrolladas por Ortony, Clore, y Foss (1987), de los términos encontrados en WordNet, una base de datos de términos en inglés agrupados en grupos de sinónimos y con relaciones semánticas entre grupos creada por Miller (1995). A partir de las anotaciones manuales de las emociones de ciertos términos presentes en la base, se estableció la categoría emocional de nuevos términos gracias a los sinónimos y las relaciones semánticas, construyendo así una base de datos de estados emocionales llamada WordNet-Affect. En esta misma línea, J. Wiebe, Wilson, y Cardie (2005) elaboraron una anotación manual de los estados emocionales presentes en las oraciones de un gran volumen de noticias, teniendo en cuenta el contexto.

En el contexto de la clasificación automática de las emociones en el texto, Alm, Roth, y Sproat (2005) utilizaron los cuentos infantiles para desarrollar un modelo de aprendizaje supervisado capaz de detectar emociones en las frases. Para ello, se elaboró una anotación manual de estas frases que constituyen la base de datos y, posteriormente, se generó un conjunto de features para dichas frases que se utilizaron para entrenar un clasificador lineal

2.2. Redes neuronales para el análisis de texto

Las técnicas tradicionales de análisis de emociones en el texto han estado principalmente basadas en la relación que existe entre los términos que conforman el texto y un estado emocional determinado. Aunque este tipo de análisis ha sido de gran utilidad, no posee la capacidad de tener en cuenta el sentido, es decir, la relación que existe entre las palabras que componen el texto, además del orden en que se

presentan. Debido a esto, recientemente el campo de estudio ha migrado hacia el uso de algoritmos capaces de captar esta relación contextual, específicamente las redes neuronales.

Con el objetivo de resumir el estado del arte, Acheampong, Nunoo-Mensah, y Chen (2021) realizaron un recuento de las distintas arquitecturas de redes neuronales utilizadas recientemente para esta tarea, incluidas las RNN (redes neuronales recurrentes), que fueron popularizadas entre otros, por Cho et al. (2014). Estas redes tienen una arquitectura adecuada para datos secuenciales, como las tareas de NLP. Son una estructura autoregresiva, generando la salida del paso $t+1$ con base en la entrada en el tiempo $t+1$ y la salida en el tiempo t . Sin embargo, debido a su arquitectura, la optimización de los pesos que conforman la topología de las RNN se vuelve compleja para el cálculo del gradiente del error, ya que se debe pasar tantas veces por los pesos de la red como pasos en el tiempo existan (como el número de caracteres en una palabra), lo que hace difícil computar secuencias particularmente largas dada la carencia de paralelización del cálculo.

Aunque las RNN permiten preservar de alguna manera la relación contextual del texto al tener una estructura secuencial, esta impide la paralelización de su cómputo, ya que se requieren las salidas de ejemplos anteriores para realizar el siguiente paso en el tiempo. Además, debido a este funcionamiento secuencial, si hay un gran número de pasos en el tiempo, es poco probable que la red considere para un punto muy adelante, información presente al inicio. Para abordar estos inconvenientes, Vaswani et al. (2017) desarrollaron los Transformers, una arquitectura en la que los datos de entrada se introducen en la red de manera simultánea, como todas las palabras en una frase por ejemplo. Esto se logra a través de una arquitectura definida como auto-atención. La auto-atención permite que una red utilice información de textos arbitrariamente

largos de manera eficiente, ya que para cada elemento en la entrada, el modelo accede a todas las entradas hasta ese elemento. Además, el cálculo para cada elemento es independiente de los demás cálculos. Esto posibilita que la representación de cada dato, en este caso cada palabra, considere su importancia con respecto las demás palabras en la oración. Esta transformación, aplicada tanto a los datos de entrada como a los de salida, se emplea para entrenar los pesos de la red. De esta manera, la red puede procesar datos de manera simultánea y tener en cuenta toda la información disponible. Un esquema de esta arquitectura se puede apreciar en la Figura 2.1.

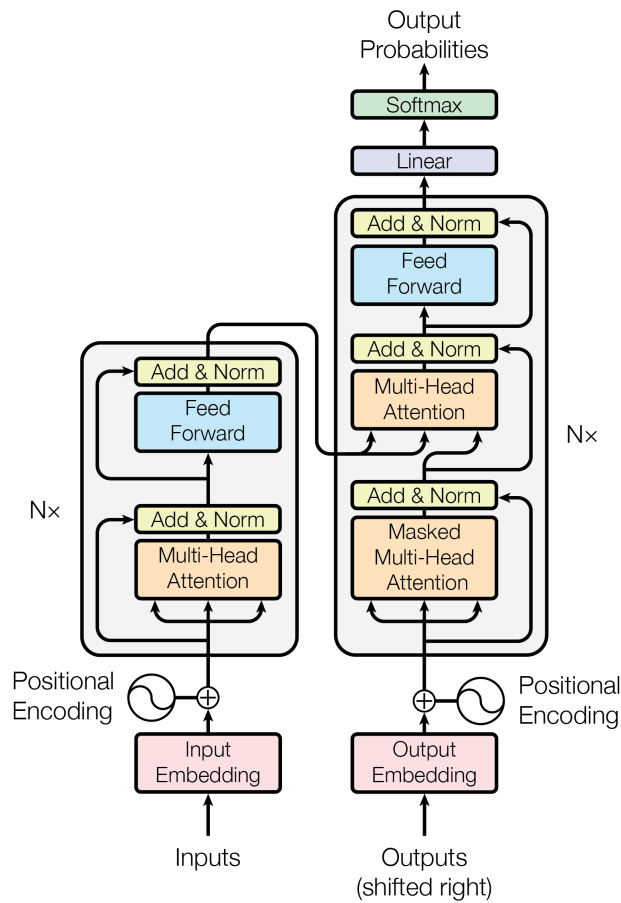


Figura 2.1: Arquitectura de los Transformers

En la figura 2.2 se muestra una comparación entre los mecanismos de auto atención de los Transformers y la estructura recurrente de las RNN, en donde se aprecia la manera de calculo simultaneo de una y secuencial de la otra.

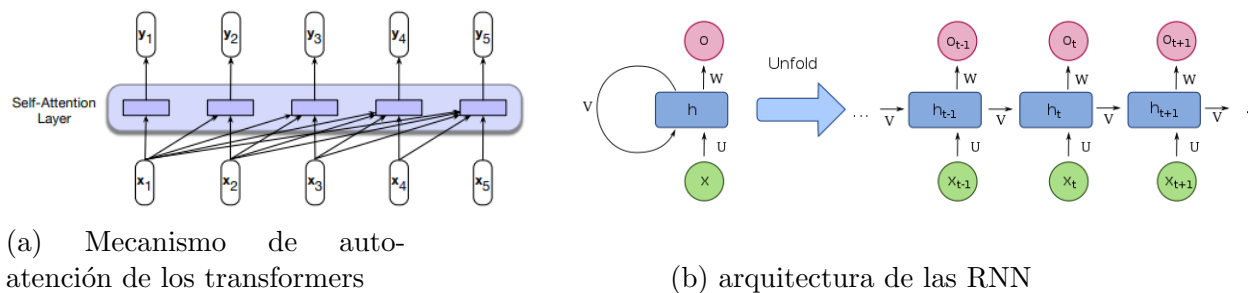


Figura 2.2: Comparación entre mecanismos de redes. Fuentes Jurafsky (2000), Wikipedia contributors (2022)

Gracias a la capacidad de paralelización y a la habilidad para conservar la relación entre palabras distantes en el texto que presentan los Transformers, es posible entrenar un modelo de lenguaje con grandes volúmenes de información para así contar con una red de gran poder predictivo. Es precisamente en este contexto que Devlin et al. (2018) desarrollaron un modelo basado en Transformers, capaz de aprender el sentido del lenguaje de manera general y luego utilizar lo aprendido para diversas tareas de procesamiento de lenguaje natural, denominado BERT (Bidirectional Transformers for Language Understanding). Para esto, se emplea una arquitectura donde las capas de entrada son las representaciones vectoriales de las palabras (Embeddings), y a partir de ahí se incluyen múltiples capas de Transformers. En su proceso de entrenamiento, se suministran dos oraciones consecutivas con palabras faltantes y se asignan dos tareas simultáneas: predecir qué palabra podría ser la faltante y determinar el orden de las oraciones. Esto le permite al modelo aprender del contexto del lenguaje a nivel de palabras, utilizando tanto las que vienen antes como

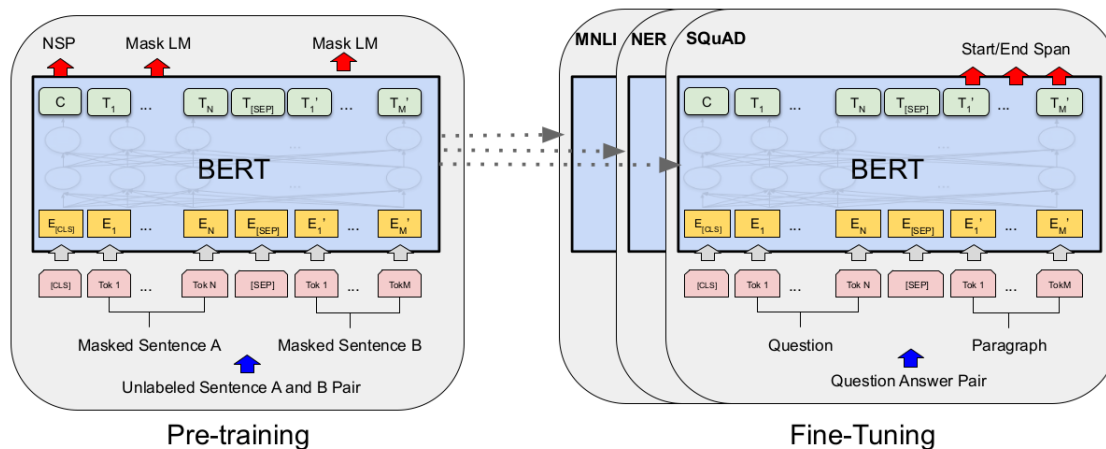


Figura 2.3: Arquitectura de BERT. Fuente Devlin et al. (2018)

las que vienen después como fuentes de información, y también aprender del contexto de las oraciones al identificar su secuencia. Para ello, se utilizó la totalidad de Wikipedia en su fase de entrenamiento. Una vez preentrenado, este modelo es capaz de utilizar su representación contextual del lenguaje para realizar diversas tareas de procesamiento de lenguaje natural, como análisis de sentimiento. Esto se logra agregando una capa final a la red que genere un posible resultado, por ejemplo, mediante una función softmax que permita asignar probabilidades a distintas clases y luego comparar este resultado con los valores esperados. El esquema de esta arquitectura se puede apreciar en la Figura 2.3.

En lo que respecta a la aplicación de modelos tipo BERT en español, Canete et al. (2020) destacan que hasta la fecha no existía un modelo de este tipo entrenado específicamente para este lenguaje, además del modelo BERT multilingüe. Por esta razón, se propusieron entrenar un modelo destinado al español, utilizando además de la Wikipedia en español, textos provenientes de publicaciones de las Naciones

Unidas, gobiernos y charlas TED. El resultado fue un modelo que supera al BERT multilingüe en múltiples tareas de evaluación para el español.

2.3. Sentimientos y emociones en redes sociales

El campo de estudio del análisis de sentimiento del texto en Internet ha cobrado cada vez más importancia, tanto para usuarios individuales como para la industria de la publicidad, el mercado financiero y la academia tal como lo describen Pang, Lee, et al. (2008). Por lo tanto, los autores realizan un repaso de las distintas técnicas y aplicaciones que consideran relevantes hasta la fecha.

Un ámbito particular donde los usuarios individuales generan grandes volúmenes de información sobre diversos temas, y es por ende una fuente rica de datos para el análisis de sentimiento, es el de los blogs. Es por esta razón que Aman y Szpakowicz (2007) emplean textos provenientes de estos para realizar la detección de emociones presentes en las oraciones. Para lograr esto, primero realizan una anotación manual de las emociones presentes en las oraciones y luego construyen features para entrenar distintos modelos supervisados.

Twitter es un sitio de blogs en particular con un formato de microblogging, lo que significa publicaciones breves llamadas "tweets". Este sitio ha ganado gran relevancia en el análisis del texto debido a su popularidad entre usuarios de Internet de diversos tipos, desde marcas hasta individuos y políticos que abordan una amplia variedad de temas. En este contexto, Pak y Paroubek (2010) extraen tweets de diferentes usuarios que tratan sobre distintos temas para llevar a cabo un análisis de sentimientos. Para ello, identifican tweets que contienen emoticones felices y tristes,

a los cuales etiquetan como reflejo de sentimientos positivos o negativos, respectivamente. También consideran tweets provenientes de cuentas de medios de noticias, los cuales etiquetan como neutrales. Luego, construyen features utilizando n-gramas a partir de las palabras presentes en los tweets, y utilizan estos features para entrenar varios clasificadores.

Reconociendo la necesidad de contar con un corpus etiquetado como base para la identificación de emociones en Twitter, Roberts, Roach, Johnson, Guthrie, y Harabagiu (2012) seleccionan 14 temas con contenido emocionalmente fuerte y sus palabras clave asociadas, para usarlas como hashtags en la extracción de tweets. Luego, etiquetan manualmente los tweets con sus respectivas emociones. Esto proporciona una base de datos para poder entrenar un modelo de aprendizaje supervisado y evaluar así el poder predictivo de los modelos a partir de datos etiquetados.

La identificación del sentimiento en Twitter puede servir como una aproximación a la realidad social de los usuarios. Por esta razón, O'Connor et al. (2010) plantean la pregunta de si existe una correlación entre el sentimiento presente en Twitter y las encuestas de opinión. Para investigarlo, extraen mil millones de tweets entre 2008 y 2009, seleccionando aquellos que contienen palabras clave asociadas a los temas en estudio. Determinan el sentimiento de estos tweets basándose en la proporción de palabras con connotaciones negativas o positivas presentes en un tema particular en un día dado. Los resultados muestran una correlación significativa entre el sentimiento reflejado en los tweets y los resultados de las encuestas. Esta relación entre la realidad social y el sentimiento en los tweets también es explorada por Bollen, Mao, y Pepe (2011), quienes miden el estado emocional de una muestra de tweets entre agosto y diciembre de 2008. Lo hacen evaluando la similitud entre las palabras de los tweets y ciertos términos clave asociados a estados emocionales. A través de esto,

identifican que ciertos eventos relevantes generan un impacto emocional significativo y duradero en los usuarios.

Dado que el ámbito político es un caso particular dentro de los fenómenos sociales y su impacto se refleja en el estado emocional de las personas, el sentimiento presente en los tweets relacionados con la política puede proporcionar un indicio de la percepción pública de ese ámbito. Con este enfoque, Tumasjan et al. (2010) proponen el uso de Twitter como plataforma para medir la percepción pública sobre la política durante las elecciones parlamentarias en Alemania en 2009. Una de sus preguntas de investigación se centra en los sentimientos expresados en los tweets que mencionan a los políticos en campaña. Utilizan un software capaz de identificar palabras clave asociadas a estados emocionales y cognitivos en el texto. El resultado es un perfil emocional para cada político que en términos generales, parece concordar con su discurso político.

Por otro lado, el análisis del contenido emocional presente en los tweets durante las elecciones presidenciales de 2012 en Estados Unidos fue abordado por S. M. Mohammad et al. (2015). En su estudio, se valieron de palabras clave específicas relacionadas con las elecciones para extraer los tweets pertinentes. Con el fin de analizar el contenido emocional de los tweets, los autores elaboraron un cuestionario detallado para etiquetar cada tweet con información precisa sobre sus sentimientos, emociones y la intención percibida del autor. Este cuestionario se diseñó de manera colaborativa y exhaustiva, considerando diferentes aspectos que podrían influir en la interpretación de los sentimientos, como la polaridad negativa o positiva, la emoción predominante y la intención subyacente detrás del tweet. Una vez diseñado el cuestionario, los autores lo sometieron a una plataforma de crowdsourcing en Amazon, donde participaron alrededor de 3000 etiquetadores en el proceso. Cada tweet fue evaluado

por varios etiquetadores, y la etiqueta final se determinó a partir de un consenso en los resultados de los etiquetadores. Este minucioso proceso de etiquetado permitió determinar la presencia de contenido emocional en aproximadamente 2000 tweets, y en caso de que existiera, identificar qué tipo de emoción estaba presente. Las opciones emocionales disponibles en el cuestionario fueron un total de 19, las cuales fueron posteriormente agrupadas en 8 categorías emocionales distintas. Las etiquetas finales derivadas del proceso de etiquetado se utilizaron para entrenar un modelo de aprendizaje supervisado, logrando un F1 score del 58.3%. El corpus etiquetado resultado de este proceso, fue puesto a disposición de la comunidad como recurso para investigaciones futuras. Dada la relevancia y proximidad de esta investigación al presente trabajo, este estudio se convirtió en una referencia crucial, inspirando en parte la metodología empleada.

Capítulo 3

Metodología

Este capítulo aborda la metodología empleada en el presente trabajo, la cual se centra en el análisis de tweets relacionados con las elecciones presidenciales en Colombia durante el período de mayo a junio de 2022. El capítulo comienza describiendo la sección de Datos, donde se detalla el proceso de obtención, análisis exploratorio y etiquetado de los datos recopilados. Posteriormente, en la sección de Modelos, se presentan los modelos de lenguaje utilizados y se expone el método correspondiente de entrenamiento y evaluación.

3.1. Datos

En esta sección se aborda la etapa inicial de recolección de datos, llevada a cabo entre la primera y segunda vuelta electoral, utilizando hashtags con contenido político. Luego se detalla el proceso de filtrado aplicado a esta base de datos para

retener únicamente los tweets relevantes, seguido de un análisis exploratorio de la información obtenida. También se describe el uso de los hashtags como herramienta para clasificar la orientación política los tweets, basándose en el contenido presente en los tweets que hacen uso de dichos hashtags.

Finalmente, se presenta el proceso de etiquetado manual de emociones en una muestra de los tweets recopilados. Se explica en detalle cómo se llevó a cabo este etiquetado, en el cual se eligieron 14 emociones posibles. Además, se establecen correlaciones entre las etiquetas asignadas por los etiquetadores, lo que resulta en la creación de etiquetas agrupadoras basadas en estas correlaciones. El proceso de asignación a las etiquetas finales para cada tweet se describe en profundidad, y se discute el nivel de acuerdo alcanzado entre los diferentes etiquetadores involucrados en el proceso.

3.1.1. Recolección y análisis exploratorio de datos

El dataset inicialmente recopilado consta de 585,001 tweets obtenidos entre el 22 de mayo y el 22 de junio de 2022, período en el que tuvieron lugar la primera y la segunda vuelta de las elecciones presidenciales en Colombia, el 29 de mayo y el 19 de junio respectivamente. Para la extracción de los datos, se utilizaron 173 tendencias, es decir, hashtags por día, con contenido político que estuvieron presentes durante este lapso. Estos hashtags se obtuvieron de diferentes sitios web ^{1 2 3}, donde se detallan los hashtags que fueron tendencia en distintos países para fechas específicas. De allí,

¹<https://getdaytrends.com/>

²<https://archive.twitter-trending.com/>

³<https://www.exportdata.io/trends/worldwide>

se seleccionaron los hashtags que estuvieron en tendencia y estaban relacionados con el tema de las elecciones en Colombia durante el periodo de estudio.

El dataset recolectado fue sometido a un proceso de filtrado para eliminar aquellos tweets con menos de 5 palabras, los que tenían una proporción de menciones o hashtags superior al 20% del total del texto y aquellos que contenían enlaces o provenían de usuarios con un número atípico de publicaciones. Esto redujo la base de datos a 193,348 tweets. A los hashtags utilizados les fue asignada alguna de tres orientaciones políticas: Izquierda, Derecha y Neutro. Esta asignación estuvo basada en la lectura de una muestra de múltiples tweets que contuvieran el hashtag, el contenido asociado a ellos y la inclinación política percibida en términos generales. En el Cuadro A.1 en la sección de apéndices, se presentan los hashtags junto con su orientación política y la cantidad de tweets asociados a cada uno. A lo largo de este trabajo, cuando se hable de sector político, se hará referencia a esta clasificación.

Cabe destacar que la asignación de un sector político en particular a un hashtag se llevó a cabo a partir de la tendencia política observada en los tweets, y aunque en términos generales los tweets asociados al hashtag presentan cierta inclinación, esto no excluye la presencia de tweets cuya tendencia política sea contraria. En el Cuadro 3.1 se proporcionan ejemplos de tweets que muestran la relación del hashtag con la orientación política. Por ejemplo, el hashtag #EstallidoSocialEs fue catalogado como de derecha debido a que generalmente presenta tweets como el primer ejemplo. Sin embargo, también existen tweets que lo utilizan para expresar apoyo al candidato de izquierda, como se observa en el segundo ejemplo. De manera similar, el hashtag #YaEsSuficiente suele ser utilizado mayormente para respaldar a la izquierda, como se ve en el tercer ejemplo. No obstante, también se encuentran casos en los que se utiliza para apoyar a un candidato de derecha, como se muestra en el cuarto ejemplo.

Numero de Ejemplo	Tweet	Orientacion política
1	@lcvelez @lafm #EstallidoSocialEs el arma de terror de Petro para obligar a votar por él.	Derecha
2	Colombia va por el cambio, a redoblar esfuerzos estos 4 días para derrotar a la corrupción. #PetroYFranciaSonElCambio #EstallidoSocialEs	Derecha
3	#YaEsSuficiente Que los medios proclives al gbno, traten de darle aire boca a boca a un moribundo electoral, FICO. Ante su estancamiento en las encuestas y la distancia que le ha tomado Petro, pretenden en 1 acto de desesperacion, el insuflarlo de votantes de los cuales carece.	Izquierda
4	#YaEsSuficiente de mentir sobre @ingrodolfohdez , vayan a bucaramanga, vean lo que hizo y ahí si hablen..	Izquierda

Cuadro 3.1: Ejemplos de tweets clasificados

La distribución de los hashtags segun la orientación política asignada se refleja en la Figura 3.1, donde se puede apreciar que el sector neutro comprende más del 40 % del total de los hashtags, mientras que la izquierda y la derecha tienen una cantidad similar, alrededor de un 28 % cada uno.

De manera similar, la Figura 3.2 muestra la distribución de los tweets según la orientación política asignada a los hashtags asociados. En esta Figura se aprecia que el sector neutro concentra la mayoría de los tweets, con más del 46 %, seguido por la izquierda con un 33 % y finalmente la derecha con cerca de un 29

Al analizar la cantidad de tweets por orientación política asignada a lo largo del tiempo, se obtienen los resultados observados en la Figura 3.3, que muestra el porcentaje de tweets de cada día para cada sector, en relación con el total de tweets dicho sector. Se puede notar que algunas fechas resultaron particularmente importantes: el 24 de mayo fue un día de debate y destaca el sector neutro, el 29 de mayo fue el día de la primera vuelta electoral, destacando los tres sectores, el 9 de junio fue cuando se divulgaron los llamados "Petro videos", unos videos filtrados que mostraban discusiones políticas del equipo de campaña de Petro, sobresaliendo la derecha. Además, las fechas cercanas al 19 de junio, día de la segunda vuelta,




Figura 3.1: Porcentaje de Hashtags según la orientación política asignada




Figura 3.2: Porcentaje de Tweets según la orientación política asignada

también presentan un aumento en la actividad y destacan los tres sectores.




Figura 3.3: Porcentaje de tweets según orientación política a lo largo del tiempo

3.1.2. Etiquetado

Se procedió a etiquetar manualmente un conjunto de 1200 tweets seleccionados mediante una muestra aleatoria estratificada proporcional a la cantidad de tweets presentes en los hashtags. Las etiquetas asignadas a cada tweet correspondieron a las emociones identificadas en los mismos.

Una emoción, según la definición de la APA en su Diccionario de Psicología (VandenBos, 2007), es un patrón complejo de reacción que involucra elementos experienciales, conductuales y fisiológicos. A través de estos elementos, un individuo intenta abordar un asunto o evento que tiene significado personal. La cualidad específica de la emoción, como el miedo o la ira, está determinada por el significado

particular que el individuo atribuye al evento. Por ejemplo, si el evento implica una amenaza, es probable que se genere miedo. Las emociones consisten en tres componentes distintos: una experiencia subjetiva, una respuesta fisiológica y una respuesta conductual o expresiva.

Dentro del contexto de este trabajo, los componentes de experiencia subjetiva y respuesta fisiológica no son accesibles. Por lo tanto, el enfoque principal durante el proceso de etiquetado se centró en la respuesta expresiva, específicamente en cómo el autor del tweet comunica a través del texto la respuesta emocional generada hacia la entidad a la cual va dirigido el tweet.

El proceso de etiquetado consistió en asignar emociones a un tweet a la vez, utilizando una plataforma de etiquetado con un esquema de selección múltiple. Se permitía asignar una o varias emociones al tweet, siguiendo las directrices establecidas en el manual de etiquetado ⁴. Esta tarea fue llevada a cabo por el autor y los directores, generando así tres etiquetas independientes para cada tweet.

Para el esquema de etiquetado, se tomó como referencia el enfoque de S. M. Mohamad et al. (2015), en el cual el etiquetador responde varias preguntas y, al ser preguntado sobre la emoción presente en el tweet, puede seleccionar entre 19 emociones distintas. En este trabajo, después de una prueba iterativa para elegir las etiquetas más adecuadas, se llegó a la elección de 14 emociones posibles, además de la categoría ".otra". Estas emociones incluyen alegría, agrado, confianza, admiración, miedo, incertidumbre, sorpresa, asombro, tristeza, decepción, asco, desagrado, ira, odio y otra. En el Cuadro 3.2 se presenta una descripción detallada de las emociones seleccionadas, basada en definiciones encontradas en el Diccionario de Psicología de la

⁴https://docs.google.com/document/d/1hoUYKMaYHSeGe0Q2FqRVyahTin6T09Mu8wt1_HY6200/edit?usp=sharing

APA, el Diccionario de Oxford ⁵, el de la RAE ⁶ y Wikipedia ⁷.

Cuadro 3.2: Descripción de las emociones usadas

Emoción	Descripción
Admiración	La admiración es una emoción social que se siente al observar a personas de competencia, talento o habilidad que superan los estándares. La admiración facilita el aprendizaje social en grupos. La admiración motiva la superación personal a través del aprendizaje de los modelos a seguir.
Agrado	Sensación moderada de felicidad o placer que siente una persona por algo que le gusta.
Confianza	La confianza implica que una parte se vuelve vulnerable ante otra, asumiendo que esta actuará en su beneficio. En una relación de confianza, el que confía no controla las acciones del otro.
Alegría	Es una emoción positiva que suele ir acompañada de bienestar. Se genera como resultado de un evento positivo.
Incertidumbre	La incertidumbre es la falta de seguridad, de confianza o de certeza sobre algo. Aparece en situaciones en las que no tenemos control total, en las que nos faltan respuestas e información, y nos puede generar inquietud, inseguridad, estrés, ansiedad e incluso miedo
Miedo	El miedo surge ante amenazas reales o imaginarias de daño físico, emocional o psicológico. En textos, se muestra como amenazas hacia el autor del mensaje o lo que se menciona, cuando está vulnerable o en desventaja.
Asombro	La condición de estar asombrado; un estado de asombro abrumador, como por sorpresa o miedo repentino, horror o admiración.
Sorpresa	Se define como una reacción provocada por algo inesperado, extraño o novedoso para la persona. En el texto está principalmente asociada a resultados inesperados o descubrimientos singulares respecto al enunciado del tweet.
Decepción	La decepción es la insatisfacción que sigue al fracaso de expectativas o esperanzas. A diferencia del arrepentimiento que se centra en elecciones personales, la decepción se enfoca en el resultado en sí. Puede generar estrés psicológico.
Tristeza	La tristeza es un dolor emocional causado por decadencia espiritual, manifestándose en llanto, abatimiento, falta de apetito, cansancio, etc. Ocurre cuando las expectativas no se cumplen o las circunstancias son dolorosas.
Desagrado	Una actitud o un sentimiento de disgusto o aversión.
Asco	Contiene una serie de estados con intensidades variables que van desde una leve aprensión hasta una intensa repulsión. Todos los estados de asco se desencadenan por la sensación de que algo es aversivo, repulsivo y/o tóxico.
Odio	El odio es una intensa respuesta emocional negativa hacia ciertas personas, cosas o ideas, generalmente relacionadas con la oposición o repulsión hacia algo. El odio a menudo se asocia con intensos sentimientos de ira, desprecio y disgusto.
Ira	La ira surge por objetivos no alcanzados o trato injusto, pudiendo ser peligrosa y relacionada con la violencia. En el texto, el autor reta o reclama por un derecho vulnerado, buscando justicia.

Este etiquetado se llevo a cabo usando la plataforma web Label Studio ⁸ que fue suministrada para cada uno de los etiquetadores, es decir el autor y los directores, a donde se cargaron los tweets a etiquetar. La plataforma permite definir una interfaz de etiquetado personalizada que es presentada en cada uno de los datos a etiquetar, en este caso, cada tweet. Para definir esta interfaz, se plantearon las preguntas nece-

⁵<https://www.oed.com>

⁶<https://www.rae.es/>

⁷<https://www.wikipedia.org/>

⁸<https://labelstud.io/>

sarias para poder etiquetar adecuadamente los tweets, basándose en el cuestionario planteado por S. M. Mohammad et al. (2015). Esto se llevo a cabo mediante un proceso iterativo, como se describe en la figura 3.4, en donde se plantearon algunas preguntas, se etiquetaron algunos tweets a partir de ellas y basándose en la experiencia de etiquetado y el acuerdo obtenido, se replantaron las preguntas. El resultado final de este proceso fue la interfaz de etiquetado que se puede observar en la Figura 3.5. Cabe resaltar que para el caso de las emociones, se permitió al etiquetador asignar múltiples etiquetas a cada tweet. Por otro lado, aun cuando la categoría "Neutro" no se encuentra disponible para ser seleccionada, aquellos tweets para los cuales la pregunta "¿Existe contenido emocional en este tweet?" fue respondida con un "No", fueron catalogados con dicha etiqueta.

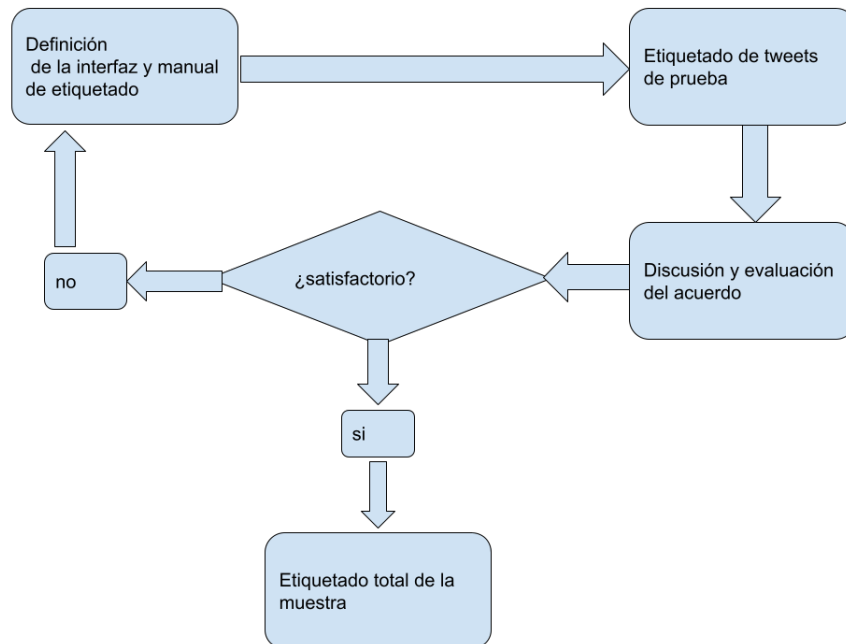


Figura 3.4: Proceso de etiquetado

A través del uso de esta interfaz, cada uno de los etiquetadores logro proporcionar

En mi casa esta prohibido hablar de política, por múltiples diferencias, pero por aquí, QUE VIVA PETRO!!!
#PetroPresidenteEnPrimera #PetroEsElCambio

¿Es relevante el presente tweet para el analisis de emociones durante la campaña presidencial?

Si^[1] No^[2]

¿Existe contenido emocional en este tweet?

Si^[3] No^[4]

¿Esta el texto escrito de manera ironica?

Si^[5] No^[6]

¿Que emocion describe mejor el texto?

Admiración^[7] Asombro^[8] Ira^[9] Decepción^[0] Asco^[1] Desagrado^[w] Miedo^[e] Odio^[l] Incertidumbre^[a] Alegría^[s]

Agrado^[d] Tristeza^[f] Sorpresa^[a] Confianza^[z] Otra^[x]

¿Si en la pregunta anterior eligio Otra, con que emocion describiria mejor el tweet?

Figura 3.5: Interfaz de etiquetado

Emocion	Cantidad etiquetador 1	Cantidad etiquetador 2	Cantidad etiquetador 3
Alegria	61	107	125
Agrado	2	36	59
Confianza	417	242	395
Admiración	79	25	292
Miedo	84	98	76
Incertidumbre	37	28	74
Sorpresa	6	3	4
Asombro	1	15	5
Tristeza	18	10	57
Decepción	137	119	74
Asco	82	119	374
Desagrado	494	357	463
Ira	26	111	161
Odio	23	0	115
Otra	4	11	21
Neutro	107	111	115

Cuadro 3.3: Cantidad de tweets asignados a cada emoción por etiquetador

sus respuestas las preguntas planteadas para cada uno de los 1200 tweets tomados como muestra. Este proceso produjo una base de datos por etiquetador que al ser consolidadas, permitió calcular la cantidad de tweets etiquetados según la emoción asignada que se observan en el Cuadro 3.3.

Al analizar las etiquetas asignadas por los etiquetadores, se encontró que estos asignaban etiquetas diferentes pero que estaban cercanas en un sentido semántico a algunos tweets. Para poder cuantificar esta situación, se procedió a calcular la correlación que tuvieron las etiquetas asignadas por los etiquetadores, obteniendo así los resultados observados en la Figura 3.6

Estos resultados llevaron a una conclusión similar a la planteada por S. M. Mohammad et al. (2015), donde resulta útil agrupar las etiquetas iniciales de manera que aquellas con cercanía semántica y, por ende, una correlación considerable en los resultados obtenidos, sean asignadas a un mismo grupo. En este sentido, se construyeron las siguientes 4 etiquetas agrupadoras: Alegría, que incluye las etiquetas Alegría, Agrado, Confianza y Admiración; Miedo, que incluye las etiquetas Miedo e Incerti-

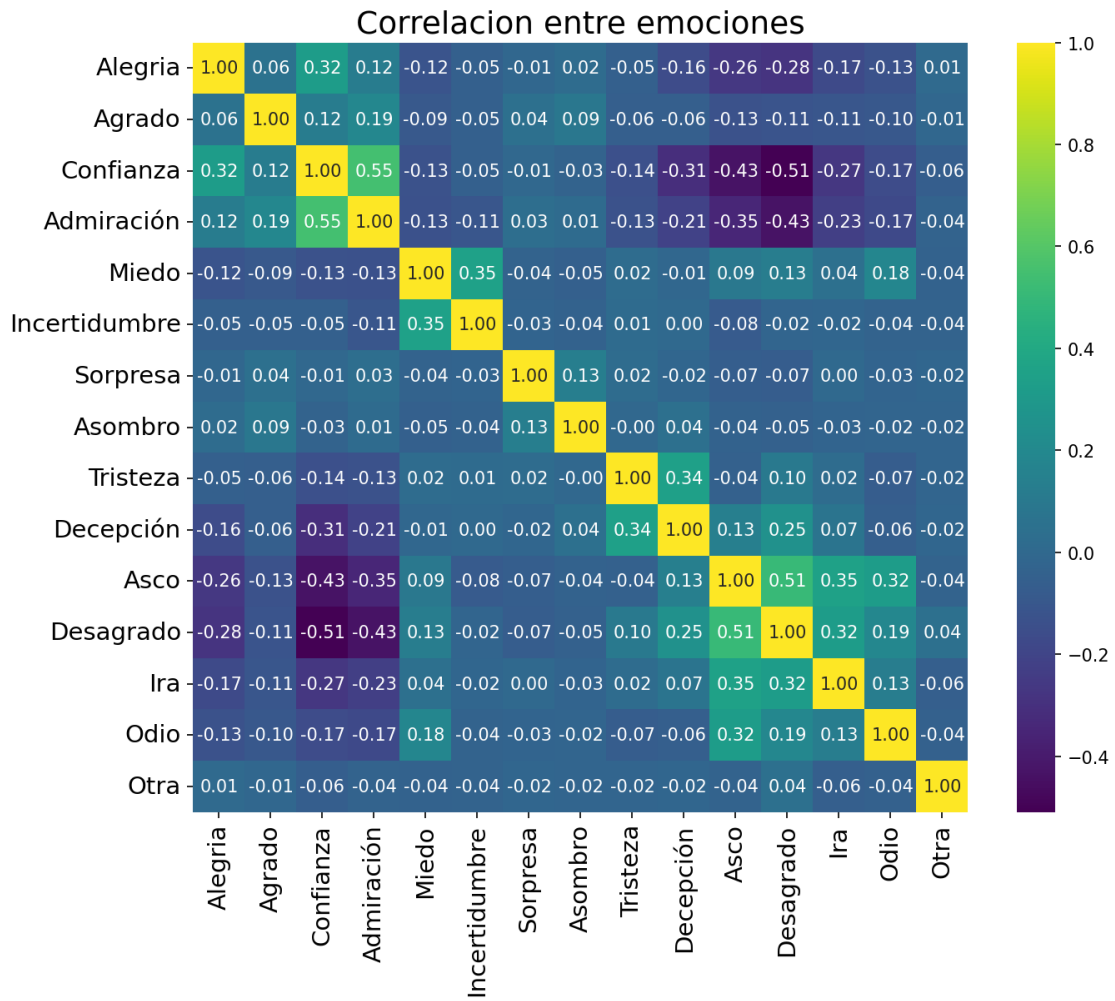


Figura 3.6: Índice de correlación entre etiquetadores de las emociones asignadas a los tweets

Cuadro 3.4: Índice de Fleiss Kappa en cada emoción

	alegria	miedo	tristeza	asco
Number of Tweets	464	98	103	580
Fleiss k index	0.69	0.47	0.4	0.62

dumbre; Tristeza, que incluye las etiquetas Tristeza y Decepción; y Asco, que incluye las etiquetas Asco, Desagrado, Ira y Odio. Por otro lado, si bien las etiquetas sorpresa y asombro presentan una leve correlación, estas fueron descartadas a que fueron muy pocos tweets a los que les fue asignadas alguna de estas etiquetas.

Para asignar las etiquetas finales a los tweets, se empleó el mismo sistema utilizado por S. M. Mohammad et al. (2015), donde más de la mitad de los etiquetadores debían estar de acuerdo en una etiqueta específica para que esta pudiera ser asignada. De esta manera, cada etiqueta agrupadora se asignó a un tweet si al menos dos de los etiquetadores le habían asignado alguna de las etiquetas que la componen. Además, debido a que se permitió a los etiquetadores asignar múltiples etiquetas a cada tweet, esto permitió la asignación de más de una etiqueta agrupadora.

El acuerdo observado entre los etiquetadores para cada una de estas 4 etiquetas agrupadoras se midió utilizando el índice de Fleiss Kappa (Fleiss, 1971). Los resultados se presentan en el Cuadro 3.4. Se puede observar que a la gran mayoría de los tweets se les asignó las etiquetas de Asco y Alegría con 464 y 580 tweets respectivamente.

Se aprecia así mismo cómo Alegría y Asco tuvieron puntajes relativamente altos en comparación con Tristeza y Miedo. Esto se explica en parte por la cercanía que estas dos últimas tienen con Asco, como se puede ver en el tweet número 1 del Cuadro 3.5. En él, dos de los etiquetadores coincidieron en asignar emociones relacionadas

Numero de Ejemplo	Tweet	Etiquetador 1	Etiquetador 2	Etiquetador 3
1	#LoPeorDeEstasElecciones es la división de la gente de este país esta gente y cosas ya que pasan	Decepción	Decepción	Desagrado
2	@Zuletalleras Son 4 años O es la. Derecha va realizar un golpe de estado? No cree a sus comentarios son ofensivos e incendiarios.... #PetroEsPresidente	Miedo, Incertidumbre	Miedo	Asco, Desagrado

Cuadro 3.5: Ejemplos de tweets clasificados por etiquetador

con Tristeza, mientras que el tercero asignó emociones relacionadas con Asco. Este mismo fenómeno ocurre con Miedo, como se aprecia en el tweet número 2 del Cuadro. Allí también fue el caso en que uno de los etiquetadores asignó emociones relacionadas con Asco, mientras que los otros dos asignaron emociones relacionadas con Miedo.

La coincidencia en las etiquetas finales asignadas a los tweets , se puede observar en la Figura 3.7, donde se representa la co-ocurrencia de estas. En esta Figura, se destaca que la etiqueta de asco fue la que se asignó conjuntamente con mayor frecuencia a todas las demás etiquetas.

En este contexto, el Cuadro 3.6 presenta la cantidad de tweets etiquetados con diferentes números de etiquetas. Los tweets con cero etiquetas corresponden a casos en los que los etiquetadores coincidieron en la ausencia de contenido emocional o hubo falta de acuerdo en la asignación de etiquetas. Es notable que la mayoría de los tweets se etiquetaron con una sola etiqueta, aunque también hay una cantidad significativa con múltiples etiquetas.

En el Cuadro 3.7 se presentan algunos ejemplos de tweets con múltiples etiquetas en la asignación final. Por ejemplo, el primer tweet comparte las etiquetas de alegría y asco debido a que el autor refleja diferentes emociones en frases distintas del tweet. Además, hay casos en los que una misma frase o todo el contenido del tweet refleja múltiples emociones para los etiquetadores. Tal es el caso de los ejemplos 2 y 3, que




Figura 3.7: Matriz de co ocurrencia entre etiquetas asignadas

Cantidad de etiquetas	Cantidad de Tweets
0	123
1	909
2	165
3	2

Cuadro 3.6: Cantidad de tweets por cantidad de etiquetas finales asignadas

comparten las etiquetas de tristeza y asco, así como el ejemplo 4, que comparte las etiquetas de miedo y asco.

Numero de Ejemplo	Tweet	Etiquetas
1	En #ElDebateDefinitivo Fajardo con sus preguntas hizo subir de votos a @petrogustavo en los votos de los indecisos. La ausencia del ingeniero ayudó a Petro, Fico pierde sólo. #PetroGanaDebate, es el único candidato que gana con argumentos.	alegria, asco
2	Comenzo el entrampamiento público en el debate presidencial. Ya ni disimulan. #ElDebateDefinitivo	tristeza, asco
3	Fajardo quedo tan peinado que ya se quiere ir #ElDebateDefinitivo	tristeza, asco
4	En conclusión #ElDebateDefinitivo deja claro que Petro es un peligro. Mentiroso, arrogante, tramposo, encubridor, manipulador, violento, pasivo agresivo, resentido. En resumen, una porquería de ser humano, qué digo humano... un demonio. Petro es el Pol Pot de Ciénaga de Oro	miedo, asco

Cuadro 3.7: Ejemplos de tweets con etiquetas múltiples

3.2. Experimentos de clasificación

En esta sección, se aborda la descripción, entrenamiento y evaluación de modelos de lenguaje preentrenados. Dado que la tarea principal de este trabajo es analizar las emociones presentes en tweets escritos en español, se han seleccionado seis modelos diferentes debido a su relevancia para dicha tarea. Cada modelo se describe de manera concisa, y se explican las herramientas utilizadas tanto para el entrenamiento como para el almacenamiento de los resultados. Además, se detalla la división de los datos realizada y se mencionan las métricas elegidas para evaluar el entrenamiento y el rendimiento de los modelos en el conjunto de test.

3.2.1. Modelos preentrenados

Los modelos de lenguaje preentrenados se encuentran disponibles para su uso en la plataforma Hugging Face ⁹, utilizando la librería Transformers ¹⁰. A partir de esta plataforma, y considerando la pertinencia de los modelos para la tarea en cuestión, se han seleccionado seis modelos distintos para ser evaluados y escoger aquel que muestre el mejor desempeño. Los modelos elegidos son RoBERTuito (Pérez, Furman, Alonso Alemany, y Luque, 2022), BERTIN (la Rosa et al., 2022), BETO Cañete et al. (2020), ELECTRICIDAD Romero (2020), RoBERTa Fandiño et al. (2022a) y twitter-XLM Barbieri, Anke, y Camacho-Collados (2022). En el Cuadro 3.8, se proporciona una breve descripción de cada uno de estos modelos.

Modelo	Descripción
robertuito	Modelo de lenguaje preentrenado para contenido generado por usuarios en español, entrenado siguiendo las pautas de RoBERTa en 500 millones de tweets.
bertin	Modelo basados en RoBERTa entrenados desde cero en la parte española de mC4 usando Flax
electricidad	Modelo base tipo Electra entrenado en el corpus BETO
beto	BETO es un modelo BERT entrenado con un gran corpus español.
roberta	Modelo base de RoBERTa y ha sido preentrenado utilizando un corpus en español de 570 GB de texto limpio
twitter-xlm	Modelo basado en XLM-roBERTa multilingüe entrenado en 198 millones de tweets y ajustado para el análisis de sentimientos.

Cuadro 3.8: Descripción de los modelos usados

3.2.2. Entrenamiento de los modelos

Debido a que el fine-tuning de estos modelos requiere una gran capacidad de cómputo, se decidió utilizar el servicio de Google Colab ¹¹, donde es posible desarrollar notebooks haciendo uso gratuito de GPUs. Allí, se empleó la librería Transformers de Hugging Face para acceder a los modelos.

⁹<https://huggingface.co/>

¹⁰<https://huggingface.co/docs/transformers/index>

¹¹<https://colab.research.google.com/>

Para entrenar los modelos, se realiza una transformación de los datos de entrada en vectores tokenizados que puedan ser interpretados por el modelo. Estos datos transformados se suministran al modelo junto con los hiperparámetros y la métrica de evaluación a utilizar.

Los principales hiperparámetros empleados incluyen la implementación de AdamW, un algoritmo de optimización propuesto por Loshchilov y Hutter (2017). Se utilizó así mismo un learning rate de $5e-05$. Además, se realizaron 3 épocas de entrenamiento en el conjunto de entrenamiento y se utilizó un batch size de 8.

3.2.3. Evaluación de los modelos

Los modelos fueron entrenados y evaluados utilizando el promedio Micro de la métrica F1 score. F1 score está definida de la siguiente manera:

$$F1 = \frac{TP}{TP + \frac{1}{2}(FP + FN)}$$

Donde TP es el número de verdaderos positivos, FP es el número de falsos positivos y FN es el número de falsos negativos en todas las clases. El Micro F1 score se calcula de la misma, pero teniendo en cuenta todas las clases presentes. Esta métrica fue elegida debido a que el modelo permite la clasificación múltiple, y con ella se puede evaluar el desempeño de las distintas clases simultáneamente.

Para entrenar y evaluar los modelos, se empleó el método Monte Carlo Cross Validation, en donde cada modelo es entrenado múltiples veces con ligeras variaciones en el tamaño de los conjuntos de train y test, entrenando así diez veces cada modelo,

registrando cada vez los resultados de su desempeño. Esto se hizo para obtener una medición más robusta, dada la naturaleza aleatoria de las redes neuronales. Se optó por no realizar una tercera partición debido a que no se llevó a cabo una optimización de los hiperparámetros, además del tamaño del conjunto de datos etiquetados. Los resultados de entrenamiento de cada modelo se registraron en la plataforma Wandb ¹², una herramienta de seguimiento de modelos. Los detalles pueden observarse en el informe del proyecto creado en dicho sitio ¹³.

¹²<https://wandb.ai/>

¹³https://api.wandb.ai/links/juanjose_if3/mtzaowe2

Capítulo 4

Resultados

En este capítulo, se presentan los resultados de la clasificación de emociones en tweets utilizando los modelos de lenguaje preentrenados. Se seleccionó el modelo RoBERTuito para la tarea de predicción debido a su excelente desempeño, especialmente en las emociones miedo y tristeza. Se examina la distribución de emociones en diferentes orientaciones políticas, observando que el sentimiento de asco es predominante en los tweets asociados a la derecha, mientras que aquellos relacionados con la izquierda tienden a mostrar más alegría. Además, se analiza cómo las emociones fluctúan en momentos clave, como días de elecciones o eventos políticos relevantes durante el periodo estudiado.

Model	Micro F1	Alegria	Miedo	Tristeza	Asco
robertuito	76.6±2.3	83.6±2.4	36.6±12.6	47.7±7.9	83.1±2.5
twitter-xlm	72.8±2.7	80.8±3.5	27.1±9.7	43.5±10.6	80.8±2.0
roberta	72.3±2.8	80.5±3.4	28.6±9.9	42.3±15.1	79.6±3.8
beto	71.5±2.0	79.5±3.1	27.4±13.3	36.3±11.1	79.4±2.2
electricidad	67.7±2.5	75.6±3.5	0.0±0.0	8.5±10.1	74.1±2.8
bertin	46.4±20.5	40.6±35.8	1.8±4.3	3.3±8.0	57.7±17.5

Cuadro 4.1: Metricas de los modelos entrenados

4.1. Desempeño de los modelos entrenados

En el Cuadro 4.1, se presentan los resultados de la métrica F1, tanto para el promedio micro como para las diferentes emociones en cada modelo. Estos valores se muestran como la media y la desviación estándar de los experimentos realizados. Es importante mencionar que debido al limitado volumen de datos disponibles, el modelo BERTIN no logró converger en uno de los entrenamientos, por lo que este resultado se excluyó. Se destaca que el modelo RoBERTuito tuvo el mejor desempeño con un F1 micro de 76.6%, convirtiéndose en la elección preferida. El desempeño de este modelo se debe a que tiene un ámbito de entrenamiento más cercano al objetivo de este trabajo, ya que se entrenó con tweets en español. A diferencia de otros modelos como BETO, que estaba entrenado en español pero no específicamente para Twitter, y twitter-XLM, diseñado para varios idiomas pero no en específico para español. La tabla también presenta los resultados de la métrica F1 para cada emoción en particular, mostrando que todos los modelos tienen un buen desempeño en alegría y asco, a excepción de BERTIN. Sin embargo, los puntajes son significativamente más bajos para miedo y tristeza en todos los modelos. No obstante, RoBERTuito obtuvo el mejor desempeño en ambas emociones.

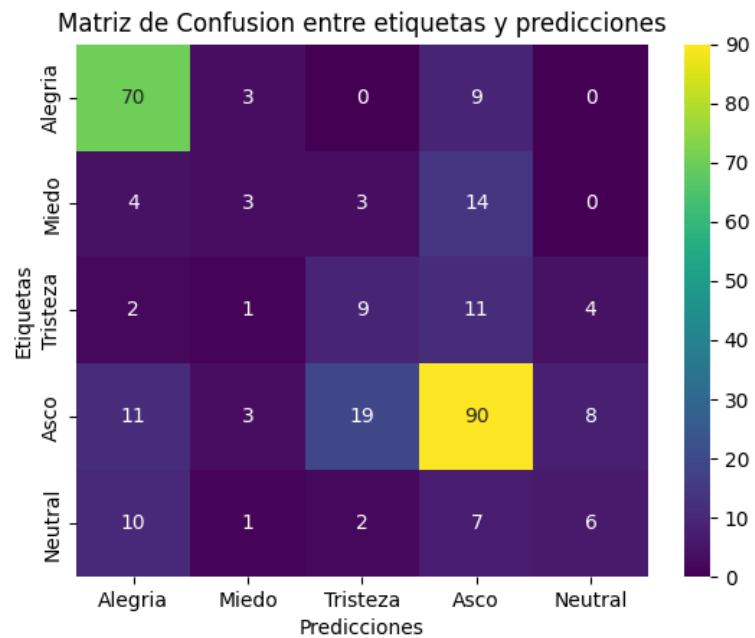


Figura 4.1: Matriz de confusión entre etiquetas asignadas y predicciones del algoritmo para el dataset etiquetado

En la Figura 4.1, se muestra una matriz de confusión con los resultados de la clasificación en el conjunto de test. Esta matriz ilustra el número de coincidencias entre las etiquetas y las predicciones. El número en cada casilla resulta de la cantidad de tweets que contaron con una etiqueta en particular y les fue asignada determinada predicción. Cabe resaltar que debido a que son permitidas etiquetas múltiples, un tweet será contado tantas veces como coincidencias posibles tenga. Se observa allí que varios de los tweets etiquetados con miedo fueron predichos como asco.

Esta situación se explica en parte porque algunos de estos tweets efectivamente contenían la emoción de miedo junto con asco, pero el modelo solo logró identificar esta última, como se ejemplifica en el tweet número 1 en el Cuadro 4.2. Esto también

ocurrió en el caso de la tristeza, como se aprecia en el tweet número 2. Para la alegría, se observa que también hubo casos en los que tweets fueron etiquetados con esta emoción pero en las predicciones les fue asignado asco. En muchos casos, esto se debió a que un mismo tweet expresaba dos emociones diferentes, una en cada frase, como se ilustra en el tweet número 3 del cuadro, en donde el autor expresa inicialmente apoyo a una persona y en la siguiente frase rechazo a otra. En relación a los tweets que no tenían etiquetas y, por ende, se representan como neutrales en la Figura 4.1, se presentó un fenómeno en el cual los etiquetadores no percibían suficiente carga emocional como para asignar una etiqueta. Sin embargo, el modelo los clasificó con la etiqueta más adecuada según su contenido, como se ilustra en el ejemplo número 4.

Numero de Ejemplo	Tweet	Etiquetas	Predicciones
1	En conclusión #ElDebateDefinitivo deja claro que Petro es un peligro. Mentiroso, arrogante, tramposo, encubridor, manipulador, violento, pasivo agresivo, resentido. En resumen, una porquería de ser humano, qué digo humano... un demonio. Petro es el Pol Pot de Ciénaga de Oro	Miedo, Asco	Asco
2	#ElDebateDefinitivo @sergio_fajardo fue a vender ilusiones y convencer no a debatir no propone sólo dice redundancias, me sorprende profe sera que de proyectos no sabe tanto como de licenciatura...	Tristeza, Asco	Asco
3	Juan Roberto Vargas es una persona decente. Néstor Morales es una porquería de persona. #DebateFinal	Alegria, Asco	Asco
4	#FedericoEsColombia Me uno Federico Gutiérrez es Colombia.	Neutral	Alegria

Cuadro 4.2: Ejemplos de tweets con divergencias entre etiquetas y clasificaciones

4.2. Distribución de emociones por orientación política

A partir del modelo entrenado se procedió al etiquetado del total del conjunto de datos, es decir los 193,348 tweets relacionados a las elecciones presidenciales en

Colombia. El agrupamiento de este etiquetado permite observar los resultados presentes en la Figura 4.2, donde se muestra el porcentaje de tweets que recibió cada una de las distintas etiquetas emocionales. En dicha figura, se puede observar que la emoción más preponderante fue el asco, abarcando más del 50% de los tweets. Luego, le sigue la alegría con aproximadamente el 40%. Por último, tanto la tristeza como el miedo tuvieron una presencia menor, rondando alrededor del 12% y el 9%, respectivamente.




Figura 4.2: Porcentaje de tweets clasificado según emociones por el algoritmo

Al examinar la distribución de cada emoción según la orientación política asignada al tweet a partir del hashtag empleado, se obtienen los resultados que se presentan en la Figura 4.3. En este gráfico, se destaca que el sector neutral fue el que mostró una mayor cantidad de tweets etiquetados con miedo, representando aproximadamente el 12% de sus tweets. Por otro lado, tanto las orientaciones derecha e izquierda tuvieron una presencia menor, alrededor del 8% y 6%, respectivamente. En cuanto a

la alegría, se revela que los tweets con orientación izquierda asignada, fueron los que presentaron una mayor frecuencia de esta emoción, alcanzando el 58%. Luego, las orientaciones neutral y derecha tuvieron alrededor de un 30% cada uno. Respecto al asco, se destaca la preeminencia de los tweets con la orientación de derecha asignada, representando un 69% del total. La orientación neutral se ubica en segundo lugar con un 60% de los tweets, mientras que los tweets con la orientación izquierda asignada tienen el menor porcentaje de los tres, un 40%. Finalmente, en relación a la tristeza, la orientación neutral fue la que mostró una mayor presencia de esta emoción con un 22% de su total, cifra significativamente mayor que las orientaciones derecha e izquierda, que tuvieron un 6% y 3%, respectivamente.




Figura 4.3: Porcentaje de tweets clasificados según emoción por el algoritmo, separado por orientación política del hashtag

4.3. Emociones a lo largo del tiempo

En la Figura 4.4, que muestra el porcentaje de tweets que tuvo cada emoción en un día específico, se puede observar que el 29 de mayo fue un día particularmente activo en términos emocionales. Durante ese día, alrededor del 27 % de los tweets estuvieron asociados con las emociones de alegría y miedo, un 20 % con tristeza y un 9 % con asco. Este día coincidió con la primera vuelta presidencial. De manera similar, entre los días 9 y 10 de junio hubo un repunte en las emociones de asco, tristeza y miedo, con porcentajes del 9 %, 6 % y 5 % respectivamente. Estos días estuvieron marcados por el evento conocido como Petro videos, que se refiere a la filtración de videos grabados durante una reunión del equipo del candidato Petro, en la que se discutían estrategias de campaña¹. Posteriormente, se observa otro aumento en las emociones de asco, miedo y tristeza alrededor del 16 de junio, fecha en la que se habló del debate final al cual el candidato Rodolfo Hernández se negó a participar. Finalmente, el 19 de junio, que corresponde a la segunda vuelta, se observa un incremento en las emociones de alegría, tristeza y miedo.

En relación a cada emoción y orientación, se obtuvo el porcentaje correspondiente que tuvieron los tweets asignados a cada orientación en un día particular. Esto se logró dividiendo el número de tweets de una orientación, con una emoción específica en dicho día entre el total de tweets de esa misma orientación con esa misma emoción. Esto se puede apreciar en la Figura 4.5 para la emoción de alegría, en la cual se observa que el 29 de mayo todas las orientaciones experimentaron un repunte en esta emoción. Posteriormente, cerca del 19 de junio, día de la segunda vuelta de las elecciones, las tres orientaciones muestran un crecimiento en la emoción de alegría,

¹<https://es.wikipedia.org/wiki/Petrovideos>




Figura 4.4: Porcentaje diario del total de tweets clasificados en cada emoción a lo largo del tiempo

que luego disminuye, primero en la derecha, seguida por la orientación neutral y finalmente en la izquierda.

En el caso del miedo, se puede observar en la Figura 4.6 un notable pico en las tres orientaciones entre el 29 de mayo y el 1 de junio, como respuesta a la primera vuelta. Posteriormente, el 9 de junio hubo un repunte del miedo en la derecha, como consecuencia del fenómeno conocido como los "Petro videos". El 14 de junio también se evidencia un aumento en el miedo en la derecha, debido a rumores de un posible estallido social. Finalmente, cerca del 19 de junio se observa un pico de miedo en las orientaciones neutro e izquierda.

En cuanto a la tristeza, se aprecia en la Figura 4.7 que las tres orientaciones tuvieron un repunte inicial cerca del 24 de mayo, como resultado de un debate. Entre el 29 de mayo y el 1 de junio, la izquierda y la orientación neutral experimentaron otro




Figura 4.5: Porcentaje diario del total de tweets clasificados como Alegría, para cada orientación política




Figura 4.6: Porcentaje diario del total de tweets clasificados como Miedo, para cada orientación política

incremento, alcanzando un 36 % y un 22 % respectivamente. El 9 de junio se observa un aumento en la tristeza en la derecha, relacionado con los "Petro videos", y el 10 de junio hubo un repunte en la orientación neutral, en el que se discutieron temas decepcionantes relacionados con las elecciones. El 14 de junio, la derecha experimentó nuevamente un aumento en la tristeza, también relacionado con la posibilidad de un estallido social. Finalmente, cerca del 19 de junio, todos los sectores mostraron un incremento en la tristeza.

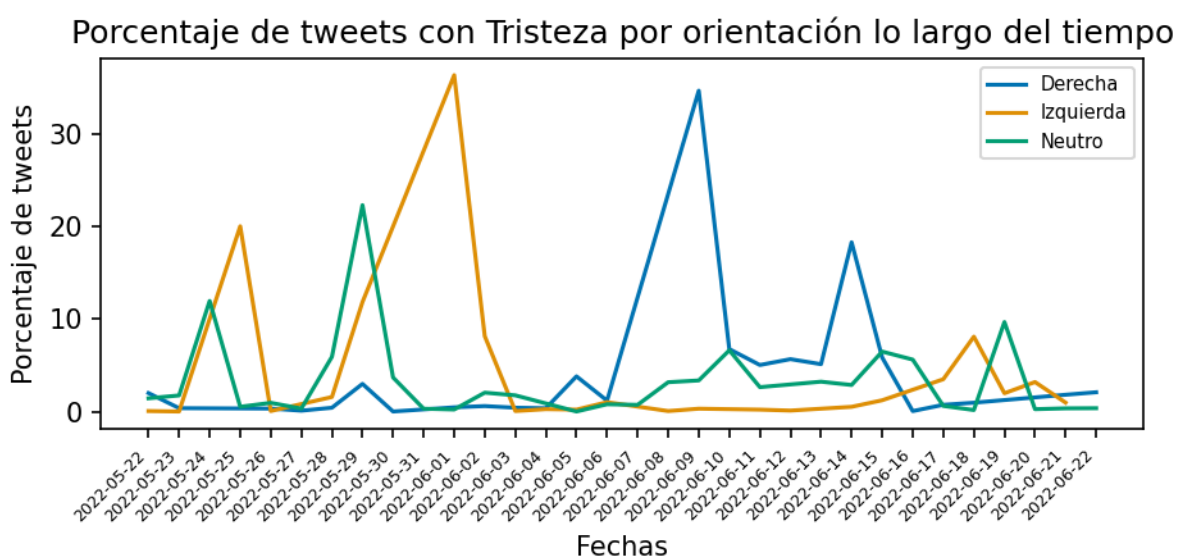


Figura 4.7: Porcentaje diario del total de tweets clasificados como Tristeza, para cada orientación política

En relación al asco, se puede observar en la Figura 4.8 que al inicio hay un pico en la orientación neutral el 24 de mayo, como reacción al debate. Luego, todas las orientaciones experimentaron un repunte el 29 de mayo. Es notable el gran pico que tuvo la derecha el 9 de junio, coincidiendo con los "Petro videos", con más del 27%. De manera similar, la izquierda alcanzó su punto máximo el 17 de junio, llegando a cerca del 20%. En esta fecha se habló de la negativa del candidato Rodolfo Hernández

a participar en el debate final.




Figura 4.8: Porcentaje diario del total de tweets clasificados como Asco, para cada orientación política

Capítulo 5

Conclusiones

El presente trabajo logró, a través del fine tuning de un modelo de lenguaje pre-entrenado, en este caso robertuito-base-uncased”, identificar las emociones presentes en los tweets relacionados con las elecciones presidenciales en Colombia del 2022. Estas predicciones permitieron poder asociar estas emociones a distintas orientaciones políticas, a partir de la asignación de una orientación a un tweet en particular, a partir del hashtag usado y la tendencia observada en el mismo. Así mismo , se pudo observar la fluctuación por emoción y por sector de los tweets a lo largo del periodo estudiado.

El proceso de fine tuning fue posible gracias a la creación de un recurso propio, un conjunto de datos de 1200 tweets etiquetados manualmente por el autor y los directores. Esta tarea de etiquetado se realizó utilizando una interfaz web y siguiendo un manual interno que permitió asignar una o varias de las 14 emociones disponibles a cada tweet. Para que una emoción fuera asignada al tweet, al menos dos etiquetadores debían coincidir en ella. Finalmente, cada tweet se clasificó con una de las

cuatro etiquetas resultantes de la agrupación de las etiquetas originales, basada en su correlación. Es importante señalar la dificultad inherente en la tarea de etiquetado, ya que intenta lograr una clasificación objetiva de una actividad subjetiva, lo que requirió un proceso iterativo para desarrollar un manual y una interfaz de etiquetado que se acercara a este propósito. Además, aunque todos los etiquetadores son hispanohablantes nativos, solo el autor es originario de Colombia, lo que llevó a que ciertos usos del lenguaje o situaciones contextuales específicas fueran más claros para él que para los otros etiquetadores.

Las agregaciones de las predicciones realizadas por el modelo coinciden con las respuestas emocionales esperadas en ciertos eventos importantes durante las elecciones. Los resultados del modelo muestran una presencia mucho mayor de alegría y asco que de miedo y tristeza, lo cual concuerda con lo observado durante el proceso de etiquetado, ya que estas dos emociones fueron menos frecuentes y a menudo acompañadas por la emoción del asco. Estas razones también explican el rendimiento relativamente más bajo en términos de capacidad predictiva para las emociones menos prevalentes, en comparación con la alegría y el asco. Es importante destacar que estos resultados se obtuvieron con una muestra de 1200 tweets etiquetados, por lo que aumentar el tamaño de la muestra podría haber mejorado el rendimiento del algoritmo, especialmente en las emociones con menor participación.

En términos generales, se observó una tendencia mayor hacia la alegría en los tweets a los que les fue asignada la orientación política de izquierda y hacia el asco por parte de la derecha. Esto se debe en parte a que el candidato victorioso fue de tendencia izquierdista, lo que generó estas respuestas emocionales en los respectivos sectores políticos, especialmente en fechas clave como el día de las elecciones.

Este trabajo pone a disposición el conjunto de datos etiquetados y el modelo utilizado para futuras investigaciones, como la identificación de emociones en español en contextos distintos al de este estudio. Asimismo, muestra cómo, para el contexto particular de las elecciones presidenciales en Colombia en 2022, los usuarios de Twitter que utilizaron los hashtags incluidos expresaron sus emociones.

Referencias

- Acheampong, F. A., Nunoo-Mensah, H., y Chen, W. (2021). Transformer models for text-based emotion detection: a review of bert-based approaches. *Artificial Intelligence Review*, 54(8), 5789–5829.
- Alm, C. O., Roth, D., y Sproat, R. (2005). Emotions from text: machine learning for text-based emotion prediction. En *Proceedings of human language technology conference and conference on empirical methods in natural language processing* (pp. 579–586).
- Aman, S., y Szpakowicz, S. (2007). Identifying expressions of emotion in text. En *International conference on text, speech and dialogue* (pp. 196–205).
- Barbieri, F., Anke, L. E., y Camacho-Collados, J. (2022). Xlm-t: Multilingual language models in twitter for sentiment analysis and beyond. En *Proceedings of the thirteenth language resources and evaluation conference* (pp. 258–266).
- Bollen, J., Mao, H., y Pepe, A. (2011). Modeling public mood and emotion: Twitter sentiment and socio-economic phenomena. En *Proceedings of the international aaai conference on web and social media* (Vol. 5, pp. 450–453).
- Canete, J., Chaperon, G., Fuentes, R., Ho, J.-H., Kang, H., y Pérez, J. (2020). Spanish pre-trained bert model and evaluation data. *Pml4dc at iclr, 2020*, 1–10.

- Cañete, J., Chaperon, G., Fuentes, R., Ho, J.-H., Kang, H., y Pérez, J. (2020). Spanish pre-trained bert model and evaluation data. En *Pml4dc at iclr 2020*.
- Cerón-Guzmán, J. A., y León-Guzmán, E. (2016). A sentiment analysis system of spanish tweets and its application in colombia 2014 presidential election. En *2016 ieee international conferences on big data and cloud computing (bdcloud), social computing and networking (socialcom), sustainable computing and communications (sustaincom)(bdcloud-socialcom-sustaincom)* (pp. 250–257).
- Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., y Bengio, Y. (2014). Learning phrase representations using rnn encoder-decoder for statistical machine translation. *arXiv preprint arXiv:1406.1078*.
- Chung, J., Gulcehre, C., Cho, K., y Bengio, Y. (2014). Empirical evaluation of gated recurrent neural networks on sequence modeling. *arXiv preprint arXiv:1412.3555*.
- Davidov, D., Tsur, O., y Rappoport, A. (2010). Enhanced sentiment learning using twitter hashtags and smileys. En *Coling 2010: Posters* (pp. 241–249).
- Devlin, J., Chang, M.-W., Lee, K., y Toutanova, K. (2018). Bert: Pre-training of deep bidirectional transformers for language understanding. *arXiv preprint arXiv:1810.04805*.
- Ekman, P. (1993). Facial expression and emotion. *American psychologist*, 48(4), 384.
- Fandiño, A. G., Estapé, J. A., Pàmies, M., Palao, J. L., Ocampo, J. S., Carrino, C. P., ... Villegas, M. (2022a). Maria: Spanish language models. *Procesamiento del Lenguaje Natural*, 68. Descargado de <https://upcommons.upc.edu/handle/2117/367156#.YyMTB4X9A-0.mendeley> doi: 10.26342/2022-68-3
- Fandiño, A. G., Estapé, J. A., Pàmies, M., Palao, J. L., Ocampo, J. S., Carrino, C. P., ... Villegas, M. (2022b). Maria: Spanish language models. *Procesamiento del*

- Lenguaje Natural*, 68. Descargado de <https://upcommons.upc.edu/handle/2117/367156#.YyMTB4X9A-0.mendeley> doi: 10.26342/2022-68-3
- Fleiss, J. L. (1971). Measuring nominal scale agreement among many raters. *Psychological bulletin*, 76(5), 378.
- Gil, G. B., Jesús, A. B. d., y López, J. M. M. (2013). Combining machine learning techniques and natural language processing to infer emotions using spanish twitter corpus. En *International conference on practical applications of agents and multi-agent systems* (pp. 149–157).
- Go, A., Bhayani, R., y Huang, L. (2009). Twitter sentiment classification using distant supervision. *CS224N project report, Stanford*, 1(12), 2009.
- Gonzalez, J. A., Hurtado, L.-F., y Pla, F. (2021). Twilbert: Pre-trained deep bidirectional transformers for spanish twitter. *Neurocomputing*, 426, 58–69.
- Hatzivassiloglou, V., y McKeown, K. (1997). Predicting the semantic orientation of adjectives. En *35th annual meeting of the association for computational linguistics and 8th conference of the european chapter of the association for computational linguistics* (pp. 174–181).
- Hochreiter, S., y Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735–1780.
- Jurafsky, D. (2000). *Speech & language processing*. Pearson Education India.
- Kouloumpis, E., Wilson, T., y Moore, J. (2011). Twitter sentiment analysis: The good the bad and the omg! En *Proceedings of the international aaai conference on web and social media* (Vol. 5, pp. 538–541).
- la Rosa, J. D., Ponferrada, E. G., Romero, M., Villegas, P., de Prado Salas, P. G., y Grandury, M. (2022). Bertin: Efficient pre-training of a spanish language model using perplexity sampling. *Procesamiento del Lenguaje Natural*, 68(0), 13–23. Descargado de <http://journal.sepln.org/sepln/ojs/ojs/index.php/>

pln/article/view/6403

- Loshchilov, I., y Hutter, F. (2017). Decoupled weight decay regularization. *arXiv preprint arXiv:1711.05101*.
- Miller, G. A. (1995). Wordnet: a lexical database for english. *Communications of the ACM*, 38(11), 39–41.
- Mohammad, S. (2012). # emotional tweets. En ** sem 2012: The first joint conference on lexical and computational semantics—volume 1: Proceedings of the main conference and the shared task, and volume 2: Proceedings of the sixth international workshop on semantic evaluation (semeval 2012)* (pp. 246–255).
- Mohammad, S., Bravo-Marquez, F., Salameh, M., y Kiritchenko, S. (2018). Semeval-2018 task 1: Affect in tweets. En *Proceedings of the 12th international workshop on semantic evaluation* (pp. 1–17).
- Mohammad, S. M., Zhu, X., Kiritchenko, S., y Martin, J. (2015). Sentiment, emotion, purpose, and style in electoral tweets. *Information Processing & Management*, 51(4), 480–499.
- O’Connor, B., Balasubramanyan, R., Routledge, B. R., y Smith, N. A. (2010). From tweets to polls: Linking text sentiment to public opinion time series. En *Fourth international aaai conference on weblogs and social media*.
- Ortony, A., Clore, G. L., y Foss, M. A. (1987). hatzivassiloglou1997predicting. *Cognitive science*, 11(3), 341–364.
- Pak, A., y Paroubek, P. (2010). Twitter as a corpus for sentiment analysis and opinion mining. En *Proceedings of the seventh international conference on language resources and evaluation (lrec’10)*.
- Pang, B., Lee, L., y cols. (2008). Opinion mining and sentiment analysis. *Foundations and Trends® in information retrieval*, 2(1–2), 1–135.
- Pang, B., Lee, L., y Vaithyanathan, S. (2002). Thumbs up? sentiment classification

- using machine learning techniques. *arXiv preprint cs/0205070*.
- Pérez, J. M., Furman, D. A., Alonso Alemany, L., y Luque, F. M. (2022, junio). RoBERTuito: a pre-trained language model for social media text in Spanish. En *Proceedings of the thirteenth language resources and evaluation conference* (pp. 7235–7243). Marseille, France: European Language Resources Association. Descargado de <https://aclanthology.org/2022.lrec-1.785>
- Picard, R. W. (2000). *Affective computing*. MIT press.
- Plaza-del Arco, F. M., Jiménez Zafra, S. M., Montejo Ráez, A., Molina González, M. D., Ureña López, L. A., y Martín Valdivia, M. T. (2021). Overview of the emoeval task on emotion detection for spanish at iberlef 2021.
- Plaza-del Arco, F. M., Martín-Valdivia, M. T., Ureña-López, L. A., y Mitkov, R. (2020). Improved emotion recognition in spanish social media through incorporation of lexical knowledge. *Future Generation Computer Systems*, 110, 1000–1008.
- Plaza-del Arco, F. M., Strapparava, C., Lopez, L. A. U., y Martín-Valdivia, M. T. (2020). Emoevent: A multilingual emotion corpus based on different events. En *Proceedings of the 12th language resources and evaluation conference* (pp. 1492–1498).
- Roberts, K., Roach, M. A., Johnson, J., Guthrie, J., y Harabagiu, S. (2012). Em-patweet: Annotating and detecting emotions on twitter. En *Proceedings of the eighth international conference on language resources and evaluation (lrec'12)* (pp. 3806–3813).
- Romero, M. (2020). *Spanish electra by manuel romero*. <https://huggingface.co/mrm8488/electricidad-base-discriminator/>. Hugging Face.
- Sidorov, G., Haro, S. N. G., y Vázquez, V. A. C. (2016). Construcción de un corpus marcado con emociones para el análisis de sentimientos en twitter en español.

Revista Escritos BUAP, 1(1).

- Sidorov, G., Miranda-Jiménez, S., Viveros-Jiménez, F., Gelbukh, A., Castro-Sánchez, N., Velásquez, F., ... Gordon, J. (2012). Empirical study of machine learning based approach for opinion mining in tweets. En *Mexican international conference on artificial intelligence* (pp. 1–14).
- Strapparava, C., Valitutti, A., y cols. (2004). Wordnet affect: an affective extension of wordnet. En *Lrec* (Vol. 4, p. 40).
- Tumasjan, A., Sprenger, T., Sandner, P., y Welpe, I. (2010). Predicting elections with twitter: What 140 characters reveal about political sentiment. En *Proceedings of the international aaai conference on web and social media* (Vol. 4, pp. 178–185).
- Turney, P. D. (2002). Thumbs up or thumbs down? semantic orientation applied to unsupervised classification of reviews. *arXiv preprint cs/0212032*.
- VandenBos, G. R. (2007). *Apa dictionary of psychology*. American Psychological Association.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... Polosukhin, I. (2017). Attention is all you need. *Advances in neural information processing systems*, 30.
- Wang, W., Chen, L., Thirunarayan, K., y Sheth, A. P. (2012). Harnessing twitter”big data”for automatic emotion identification. En *2012 international conference on privacy, security, risk and trust and 2012 international confernece on social computing* (pp. 587–592).
- Wiebe, J., Wilson, T., y Cardie, C. (2005). Annotating expressions of opinions and emotions in language. *Language resources and evaluation*, 39(2), 165–210.
- Wiebe, J. M. (1994). Tracking point of view in narrative. *arXiv preprint cmp-lg/9407019*.

- Wikipedia contributors. (2022). *Recurrent neural network* — *Wikipedia, the free encyclopedia*. https://en.wikipedia.org/w/index.php?title=Recurrent_neural_network&oldid=1109264340. ([Online; accessed 26-September-2022])
- Yu, H., y Hatzivassiloglou, V. (2003). Towards answering opinion questions: Separating facts from opinions and identifying the polarity of opinion sentences. In *Proceedings of the 2003 conference on empirical methods in natural language processing* (pp. 129–136).

Apéndice A

Anexos

Cuadro A.1: Hashtags

date	trending	Sector	Count
2022-05-22	NosUnimosONosJodemos	Derecha	427
2022-05-22	FedericoEsColombia	Derecha	1597
2022-05-22	LoPeorDeEstasElecciones	Neutro	357
2022-05-22	MiVotoEsPetroYFrancia	Izquierda	2131
2022-05-23	MiVotoEsPetroYFrancia	Izquierda	2131
2022-05-23	UnTramposoEs	Neutro	1255
2022-05-23	FedericoEsColombia	Derecha	1597
2022-05-23	MeInquieta	Neutro	696
2022-05-24	ElDebateDefinitivo	Neutro	7546
2022-05-24	AColombiaLePreocupa	Neutro	1088
2022-05-24	LeApuestoA	Neutro	326
2022-05-24	UnTramposoEs	Neutro	1255
2022-05-24	GrandezaEs	Neutro	498
2022-05-25	VotoPor	Neutro	1093
2022-05-25	YaEsSuficiente	Izquierda	816
2022-05-25	ElDebateDefinitivo	Neutro	7546

Continúa en la siguiente página

Cuadro A.1: Hashtags

date	trending	Sector	Count
2022-05-25	vanessapregúnteleafico	Izquierda	323
2022-05-25	AColombiaLePreocupa	Neutro	1088
2022-05-25	ConvenceUnoMásPorPetro	Izquierda	174
2022-05-26	FicoElGanador	Derecha	2578
2022-05-26	ElMejorCandidatoEs	Neutro	1681
2022-05-26	ElDebateDecisivo	Neutro	1305
2022-05-26	PetroEsElCambio	Izquierda	457
2022-05-26	MagdalenaVotaPetro	Izquierda	150
2022-05-27	PetroEs	Neutro	877
2022-05-27	EsElMomentoDe	Neutro	1334
2022-05-27	FicoElGanador	Derecha	2578
2022-05-27	ElDomingoVoyA	Neutro	298
2022-05-27	ElMejorCandidatoEs	Neutro	1681
2022-05-28	LaVidaEnUnVoto	Izquierda	221
2022-05-28	VoyConFico	Derecha	78
2022-05-28	YoVotoPetroPresidente	Izquierda	3376
2022-05-28	DebateFinal	Neutro	5217
2022-05-28	VoyConFederico	Derecha	4148
2022-05-28	FicoElGanador	Derecha	2578
2022-05-29	EleccionesColombia	Neutro	7088
2022-05-29	CualquieraMenosPetro	Derecha	957
2022-05-29	Elecciones2022	Neutro	5978
2022-05-29	PetroPresidenteEnPrimera	Izquierda	4032
2022-05-29	PetroPresidente2022	Izquierda	1712
2022-05-29	ElCambioEnPrimera	Izquierda	3077
2022-05-29	SegundaVuelta	Neutro	1752
2022-05-29	MiVotoEsSecretosky	Izquierda	734
2022-05-29	VotoPorFicoYLara	Derecha	846
2022-05-29	PetroNuncaSeráPresidente	Derecha	461
2022-05-29	HoyMeIdentifiCO	Derecha	92
2022-05-29	YoVotoPetroPresidente	Izquierda	3376
2022-05-29	ColombiaConPetro	Izquierda	3263
2022-05-29	VoyConFederico	Derecha	4148
2022-05-29	ColombiaDecide	Neutro	3906

Continúa en la siguiente página

Cuadro A.1: Hashtags

date	trending	Sector	Count
2022-05-29	HoyGana	Neutro	687
2022-05-29	PetroYFranciaSonElCambio	Izquierda	637
2022-05-29	PetroNUNCAseraPresidente	Derecha	461
2022-05-30	SegundaVuelta	Neutro	1752
2022-05-30	LaPrimeraVueltaFue	Neutro	693
2022-05-30	Elecciones2022	Neutro	5978
2022-05-30	VotoPorFicoYLara	Derecha	846
2022-05-30	HoyGana	Neutro	687
2022-05-31	SegundaVuelta	Neutro	1752
2022-05-31	MiCandidatoEs	Neutro	2123
2022-06-01	FraudeElectoral	Izquierda	2814
2022-06-01	VelezPregunteleAPetro	Derecha	192
2022-06-01	pactosabroso	Izquierda	79
2022-06-01	ElVerdaderoCambioEs	Neutro	787
2022-06-01	RodolfoPresidente2022	Derecha	2720
2022-06-01	CreoEnColombiaPor	Neutro	658
2022-06-01	Antipetrismo	Derecha	176
2022-06-02	MeSumoA	Neutro	307
2022-06-02	ColombiaNecesita	Neutro	2381
2022-06-02	RodolfoPresidente2022	Derecha	2720
2022-06-02	UnaPreguntaParaPetroFm	Derecha	850
2022-06-02	FraudeElectoral	Izquierda	2814
2022-06-02	ElDebateFeminista	Izquierda	56
2022-06-03	PetroElCambioSeguro	Izquierda	3145
2022-06-03	RodolfoPresidente2022	Derecha	2720
2022-06-03	ColombiaQuiere	Neutro	600
2022-06-03	ColombiaNecesita	Neutro	2381
2022-06-03	UnDesastre	Neutro	357
2022-06-04	PetroElCambioSeguro	Izquierda	3145
2022-06-04	YoPactoConPetro	Izquierda	761
2022-06-04	RodolfoPresidente2022	Derecha	2720
2022-06-05	LaCorrupcionPetrista	Derecha	1492
2022-06-05	VotarEnBlancoEs	Neutro	1466
2022-06-05	GraciasPero	Neutro	719

Continua en la siguiente pagina

Cuadro A.1: Hashtags

date	trending	Sector	Count
2022-06-05	PetroElCambioSeguro	Izquierda	3145
2022-06-06	VotarEnBlancoEs	Neutro	1466
2022-06-06	MeLimpioELCuloConEsaLey	Izquierda	149
2022-06-06	LaCorrupciónPetrista	Derecha	775
2022-06-06	GraciasPero	Neutro	719
2022-06-06	AliasElIngeniero	Izquierda	505
2022-06-07	UnaVerdadEs	Neutro	1504
2022-06-07	VotarEnBlancoEs	Neutro	1466
2022-06-08	UnaBurlaEs	Neutro	1467
2022-06-08	YoContratoAPetro	Izquierda	1511
2022-06-08	NoQuiero	Neutro	921
2022-06-08	UnaVerdadEs	Neutro	1504
2022-06-08	ConPetroGanasTú	Izquierda	259
2022-06-09	PetrismoSucio	Derecha	5447
2022-06-09	RumboALaVictoria	Izquierda	271
2022-06-09	PetroVideos	Derecha	2011
2022-06-09	MeDaVergüenza	Neutro	195
2022-06-09	PetroNoMateaRodolfo	Derecha	37
2022-06-09	NoTodoVale	Neutro	257
2022-06-09	PetroMentiroso	Derecha	524
2022-06-09	LosPetroVideosSon	Derecha	3034
2022-06-09	TodoVale	Neutro	796
2022-06-09	YoContratoAPetro	Izquierda	1511
2022-06-09	ColombiaEspera	Neutro	918
2022-06-10	HablaMalDeColombia	Neutro	2231
2022-06-10	PetrismoSucio	Derecha	5447
2022-06-10	PetroVideos	Derecha	2011
2022-06-10	CampañaSuciaEs	Neutro	1149
2022-06-10	MeVoyConElIngeniero	Derecha	278
2022-06-11	SoyPetroSoyPaz	Izquierda	2125
2022-06-11	PetroVideos	Derecha	2011
2022-06-11	HablaMalDeColombia	Neutro	2231
2022-06-11	PetrismoSucio	Derecha	5447
2022-06-11	QuéCansancio	Neutro	459

Continúa en la siguiente página

Cuadro A.1: Hashtags

date	trending	Sector	Count
2022-06-12	LaMaldadPetrista	Derecha	2152
2022-06-12	SoyPetroSoyPaz	Izquierda	2125
2022-06-12	ArizabaletaLameCulos	Izquierda	328
2022-06-13	ArizabaletaSicarioMoral	Izquierda	386
2022-06-13	PetroRespondaleAlosNiños	Derecha	332
2022-06-13	VanessaEnSegundaVotoPor	Neutro	199
2022-06-13	UnGolpeBajoEs	Neutro	676
2022-06-13	EsUnaBajeza	Neutro	501
2022-06-13	LaGranEncuesta	Neutro	70
2022-06-13	LaMaldadPetrista	Derecha	2152
2022-06-13	NosFalta	Neutro	1155
2022-06-14	PetrismoAcosaALaPrensa	Derecha	461
2022-06-14	YoBloqueoASemana	Izquierda	3508
2022-06-14	LaCuotaDeBenedetti	Derecha	416
2022-06-14	EstallidoSocialEs	Derecha	1964
2022-06-14	NoMeDejaDormir	Neutro	1178
2022-06-15	DebateObligadoEs	Neutro	3491
2022-06-15	YoBloqueoASemana	Izquierda	3508
2022-06-15	LoCorrectoEs	Neutro	1495
2022-06-15	CaracolPetrista	Derecha	409
2022-06-15	presidentepetro	Izquierda	859
2022-06-15	EstallidoSocialEs	Derecha	1964
2022-06-16	IrrespetuosoEs	Neutro	2125
2022-06-16	debate	Neutro	791
2022-06-16	NosHaceFalta	Neutro	985
2022-06-16	RodolfoElPresidentedelPueblo	Derecha	408
2022-06-16	MeDecepciona	Neutro	452
2022-06-17	RHGanador	Derecha	2277
2022-06-17	RodolfoCobarde	Izquierda	4843
2022-06-17	YoVotoPor	Neutro	1748
2022-06-17	EsteDomingo	Neutro	1033
2022-06-17	PetroPresidenteEnsegunda	Izquierda	1359
2022-06-18	ExguerrilleroOIngeniero	Neutro	2760
2022-06-18	RegistraduriaResponda	Izquierda	3107

Continúa en la siguiente página

Cuadro A.1: Hashtags

date	trending	Sector	Count
2022-06-18	MiVotoEsAntiFraude	Izquierda	1592
2022-06-18	RHGanador	Derecha	2277
2022-06-18	PetroPresidenteEnsegunda	Izquierda	1359
2022-06-19	PetroEsPresidente	Izquierda	15521
2022-06-19	Elecciones2022	Neutro	5978
2022-06-19	EleccionesPresidenciales2022	Neutro	327
2022-06-19	ExguerrilleroOIngeniero	Neutro	2760
2022-06-19	EleccionesColombia2022	Neutro	4484
2022-06-19	RegistraduriaResponda	Izquierda	3107
2022-06-19	VivirSabroso	Izquierda	790
2022-06-20	PetroEsPresidente	Izquierda	15521
2022-06-20	ExguerrilleroOIngeniero	Neutro	2760
2022-06-20	Elecciones2022	Neutro	5978
2022-06-21	PetroEsPresidente	Izquierda	15521
2022-06-21	NuestraPrioridadEs	Neutro	1253
2022-06-21	PetroBastaYa	Derecha	564
2022-06-21	DePetroEspero	Neutro	429
2022-06-21	PetroNecesita	Neutro	377
2022-06-22	EsMuyImportante	Neutro	1255
2022-06-22	PetroBastaYa	Derecha	564
2022-06-22	LosImpuestosDePetro	Neutro	359