

Identificación de emociones en textos de una red social

Identification of emotions in texts of a social network

Alejandra Carolina Cardoso¹, María Lorena Talamé¹, Matías Nicolás Amor¹ y Agustina Monge¹

Ingeniería en Informática / artículo científico

Citar: Cardoso, A. C., Talamé, M. L., Amor, M. N. y Monge A. (2020). Identificación de emociones en textos de una red social. *Cuadernos de Ingeniería*, 12. Recuperado de: <http://revistas.ucasal.edu.ar>

Recibido: febrero/2020

Aceptado: junio/2020



Resumen

Las redes sociales se suelen utilizar para expresar opiniones sobre diferentes aspectos de la sociedad, como productos, servicios, política, celebridades, etc. Empresas, organizaciones y gobiernos han mostrado su interés en conocer las opiniones que los usuarios tienen sobre sus actividades o productos. Además de determinar si una opinión es positiva o negativa, resulta interesante establecer cuál es el sentimiento o emoción manifestada en la opinión. Identificar la emoción que un usuario expresa en un mensaje textual puede entenderse como clasificar o categorizar el mensaje según sus características. En este trabajo, se desarrolló un método para clasificar textos breves u opiniones de la red social Twitter según la emoción que expresan. En primer lugar, fue necesario estructurar los textos descartando las partes irrelevantes y tratando de mantener la mayor cantidad de información posible. Luego se utilizaron técnicas de aprendizaje automático para la generación de un corpus de opiniones etiquetadas. Por último, se aplicó un método de clasificación por ponderación con diccionarios léxicos asociados a tres valores emocionales: valencia, activación y dominancia.

Palabras clave: emociones, Twitter, procesamiento de lenguaje natural, aprendizaje

Abstract

Social networks are often used to express opinions on different aspects of society, products, services, politics, celebrities, etc. Companies, organizations and governments have shown interest in knowing what users think about their activities or products. In addition to determining

¹ Facultad de Ingeniería, Universidad Católica de Salta (UCASAL), Argentina.

whether an opinion is positive or negative, it is interesting to determine what the feeling or emotion expressed in the opinion is. Identifying the emotion that a user expresses in a textual message can be understood as classifying or categorizing the message according to its characteristics.

In this work, a method was developed to classify short texts or opinions of the social network Twitter, according to the emotion they express. First, it was necessary to structure the texts by

discarding irrelevant parts, but trying to keep as much information as possible. Then, automatic learning techniques were used to generate a corpus of tagged opinions. Finally, a method of classification by weighting was applied with lexical dictionaries associated with three emotional values: valence, activation and dominance.

Key words: emotions, Twitter, natural language processing, learning

1. Introducción

Dado el aumento de los comentarios textuales en las redes sociales, donde los usuarios pueden expresar sus pareceres sobre un determinado producto, persona o suceso, hay un interés cada vez mayor en conocer y analizar estos comentarios. La detección automática de emociones en las opiniones de usuarios, clientes o alumnos puede ayudar a los responsables de distintas áreas a prevenir problemas o medir el nivel de satisfacción. Las redes sociales hacen posible conocer en tiempo real las opiniones que los usuarios expresan sobre una gran variedad de temas.

La identificación del sentimiento o emoción de un usuario, expresado en un mensaje textual, puede entenderse como la clasificación o categorización del mensaje según sus propias características.

Este trabajo se desarrolló en el marco de un proyecto de investigación de la Universidad Católica de Salta y tuvo como objetivo el aprendizaje de métodos para la clasificación de textos subjetivos según la emoción expresada en ellos. Los textos se obtuvieron de la red social Twitter y se clasificaron en cuatro categorías o sentimientos: ira, felicidad, asco y tristeza. Debido a las características de los textos de opinión, sin formato, informales, con errores de ortografía, o con imágenes, fue necesario realizar una serie de acciones a modo de limpieza y preparación con el fin de eliminar las características poco significativas y mantener la mayor cantidad de información posible.

Se experimentó con dos formas de clasificación textual: el aprendizaje automático, para el cual fue necesario construir un modelo que otorgara una etiqueta a un conjunto de textos sin etiquetar, y también el aprendizaje con diccionarios léxicos puntuados con tres valores asociados a las dimensiones afectivas.

2. Procesamiento de lenguaje natural

El procesamiento de lenguaje natural (PLN) es un área de la inteligencia artificial que estudia la interacción entre las personas y las computadoras utilizando lenguas naturales o humanas, de forma oral o escrita. Es un área de investigación y producción científica muy activa, con numerosas aplicaciones, por ejemplo, búsqueda de respuestas automáticas, corrección ortográfica,

reconocimiento de voz, generación de resúmenes, traducción automática y análisis de sentimientos, entre otras. Muchas de estas aplicaciones se realizan a partir de textos publicados en Internet y muy frecuentemente a partir de textos de redes sociales.

Las tareas básicas del PLN implican dividir los textos en piezas elementales como palabras u oraciones, entender las relaciones entre esas piezas y comprender su significado cuando se combinan en distintas formas. Estas tareas facilitan la «normalización» de los textos, de manera tal de obtener una representación estructurada de estos.

Herramientas para procesamiento de texto

Existe una variedad de herramientas para el procesamiento de textos, para diversos idiomas, que facilita cualquier tipo de investigación en este campo. Python (<https://www.python.org>) y R (<https://www.r-project.org>) son los lenguajes de programación más utilizados por la comunidad científica para la ciencia de datos y PLN (Blog Master Data Science, 2019).

En este proyecto se utilizó Python y librerías Open Source no solo para las tareas propias del procesamiento de textos, sino también para las posteriores de aprendizaje y clasificación. En Talamé, Cardoso, & Amor (2019) se analizaron las características de algunas herramientas aplicadas al conjunto de textos de este proyecto y se concluyó que, entre las librerías disponibles, Freeling (Padró & Stanilovsky, 2012) y Stanford NLP (Qi, Dozat, Zhang, & Manning, 2018) resultaron las más convenientes para la segmentación, tokenización y lematización del corpus de este trabajo.

3. Análisis de sentimientos

En el análisis de sentimientos, se avanzó notablemente en la detección de la polaridad de las opiniones, es decir, en determinar si son positivas o negativas (por ejemplo, Selva Castelló, 2015). Con frecuencia, también se considera la opinión neutra para diferenciar textos objetivos. Los estudios enfocados en la identificación de uno o más sentimientos en textos son escasos.

Los estudios más populares para la clasificación de sentimientos se basan en dos métodos: por un lado, el aprendizaje automático en el cual los algoritmos utilizados deben ser entrenados con un conjunto de datos suficientemente grande y previamente etiquetado con las categorías correspondientes, y por el otro, el uso de diccionarios léxicos, es decir, una lista de palabras con un determinado peso o categoría emocional. En Kolchyna, Souza, Treleanven, & Aste (2015) se combinan los dos enfoques para la clasificación de textos de opinión.

Respecto de los recursos lingüísticos, existe una variedad para el idioma inglés, entre ellos SentiWordNet (Baccianella, Esuli, & Sebastiani, 2010) que contiene más de 15000 palabras, entre sustantivos, verbos, adjetivos y adverbios; ANEW (Bradley & Lang, 1999) y Mohammad (2018) son colecciones de términos puntuados en función de las dimensiones emocionales: valencia, dominancia y activación. Con respecto a nuestro idioma, la adaptación de ANEW al español (Redondo, Fraga, Padrón, & Comesaña, 2007) contiene, aproximadamente, 1000 términos y, entre otros trabajos, fue utilizado en Miranda, Guzmán, & Salcedo (2016) para

analizar las opiniones de clientes de hoteles. En el trabajo de Díaz Rangel, Sidorov & Suárez Guerra (2014), se creó un diccionario de palabras asociadas a uno de seis sentimientos: alegría, enojo, miedo, tristeza, sorpresa y repulsión.

Usualmente los clasificadores usan datos etiquetados para ser entrenados (aprendizaje supervisado), sin embargo, los datos etiquetados y en grandes cantidades son difíciles de obtener o no existen repositorios que los contengan. El entrenamiento y aprendizaje semisupervisado intenta solucionar este problema usando grandes cantidades de datos no etiquetados junto con cantidades pequeñas de datos etiquetados para construir un modelo clasificador. Dharmadhikari, Ingle & Kulkarni (2012) realizaron un estudio de algoritmos semisupervisados y concluyeron que son aplicables para dominios multietiquetas.

Emociones

Las emociones son estudiadas en muchos campos, por ejemplo, la psicología, filosofía, sociología, biología, etc. En el caso particular de la información textual, se refiere a la emoción que se produce en un individuo cuando escribe o lee una palabra o una frase.

Si bien no hay un conjunto de emociones básicas en las que coincidan los investigadores, en este trabajo se optó por la clasificación de emociones consideradas básicas por el psicólogo Paul Ekman (1972):

Asco: expresa una marcada aversión producida por algo fuertemente desagradable o repugnante.

Ira: se expresa a través del resentimiento, la irritabilidad y respuestas agresivas.

Miedo: incita la evitación y el escape ante una amenaza o peligro.

Felicidad: estado emocional agradable, engloba un amplio rango de sentimientos, desde la satisfacción hasta la euforia.

Tristeza: se experimenta ante una pérdida o un duelo.

Sorpresa: sensación de incertidumbre que se experimenta ante un evento inesperado o imprevisto.

Una forma de representar las emociones es mediante tres componentes o factores: la valencia, la activación y la dominancia.

Valencia: indica el nivel de agrado ante un estímulo; el rango de valoración está entre lo agradable y lo desagradable.

Activación (excitación): indica la intensidad de la emoción que provoca un estímulo, desde calmado hasta activado.

Dominancia: indica el grado de control que ejerce un estímulo sobre el individuo. Se establece entre dominante y sumiso.

Cada emoción se puede entender como una mezcla de los tres factores. Por ejemplo, felicidad es una emoción con alta valencia y baja dominancia; y, por el contrario, tristeza tiene baja valencia. Sin embargo, los niveles de activación son similares en ambas emociones.

4. Arquitectura

La solución propuesta para el problema de identificar emociones en opiniones textuales consistió en varias etapas (Figura 1). En la primera se recopilieron mensajes emitidos en la red social Twitter (llamados *tweets*), los cuales fueron seleccionados, preparados y luego transformados para normalizarlos. En la etapa siguiente, se utilizaron algoritmos de aprendizaje automático para generar un corpus suficientemente grande y clasificado que sirviera como base para evaluar el método de ponderación con diccionarios léxicos en la etapa final.



Figura 1: Arquitectura del sistema propuesto.

A continuación, se explican las etapas de la arquitectura propuesta.

Recopilación de mensajes

Son escasos los corpus de opiniones textuales en idioma español disponibles para investigaciones, y los existentes suelen indicar la polaridad que expresan. Al no encontrar corpus etiquetados con emociones, fue necesario crear un conjunto de textos para realizar los experimentos. Se optó por la red social Twitter, como fuente de datos, por ser una de las más populares y con mayor tráfico textual. En el *ranking* de países con mayor interacción en las redes sociales durante el año 2019, la Argentina se encuentra entre los 20 con mayor cantidad de usuarios de Twitter, junto a otros 3 de América Latina (Kemp, 2019).

La primera etapa de la recopilación consistió en la captura de *tweets* utilizando la API de Twitter (Twitter, s.f.) durante cinco meses, a partir de una serie de *hashtags* relacionados con los temas tendencias de esos momentos. Los mensajes se almacenaron en una base de datos NoSQL para su posterior tratamiento. Este proceso se realizó bajo las siguientes condiciones:

- tweets* escritos en idioma español;
- generados en la Argentina, según el identificador de geolocalización;
- se descartaron mensajes que solo contenían imágenes o poco texto para el análisis posterior;
- se evitó la duplicidad de la información eliminando los *retweets* (*tweet* replicado por otro usuario).

Preparación

En los comentarios de las redes sociales, por lo general, no se tienen en cuenta las reglas ortográficas, se utilizan abreviaturas y, algunas veces, se acentúan emociones con el uso de *emojis*, repetición de letras, palabras en mayúsculas o signos de exclamación. Por esta razón, se realizaron una serie de acciones a modo de limpieza y preparación de los textos con el fin de mantener la mayor cantidad de información y descartar las partes irrelevantes.

Se eliminaron las palabras vacías (*stopwords*), las URLs y nombres de usuarios; se sustituyeron las abreviaturas por sus palabras equivalentes; se reemplazaron los *emojis* por su traducción textual, entre otras acciones de transformación de *tweets* (Amor, Monge, Talamé, & Cardoso, 2019).

Para el etiquetado de los *tweets* se propusieron las seis categorías de emociones consideradas básicas, según Paul Ekman (1972): asco, felicidad, ira, tristeza, miedo y sorpresa. Además, se agregó otra categoría para indicar que el *tweet* no expresaba sentimiento (podría tratarse de una publicidad o noticia, es decir, el texto no era subjetivo) o este era confuso. Se seleccionaron al azar un conjunto de *tweets* para ser etiquetados manualmente por cuatro personas. Se consideró la categoría elegida por la mayoría como clasificación final de cada *tweet*. Es importante destacar que el etiquetado manual en muchos casos resultó difícil por la falta de orden en la escritura, sentimientos confusos o irregularidades lingüísticas, lo que muchas veces generó debate en el equipo, y se descartaron mensajes por no haber coincidencia en la mayoría de los etiquetadores. De esta forma se logró etiquetar más de 600 *tweets*.

Creación del corpus inicial

La cantidad de mensajes etiquetados se consideró insuficiente para el aprendizaje de clasificación, por lo tanto, se procedió a generar un corpus mayor mediante una combinación de algoritmos de clasificación supervisados y semisupervisados.

Del corpus etiquetado se observó una marcada diferencia en las cantidades de *tweets* de las clases miedo, sorpresa y felicidad, por lo cual se decidió aplicar algunas acciones para asegurar un conjunto de datos balanceado para la etapa posterior. Los algoritmos de aprendizaje supervisado suelen tener mejor *performance* si los conjuntos de datos son balanceados; de otra manera, podrían catalogar erróneamente instancias de la clase minoritaria. Los *tweets* etiquetados con las emociones miedo y sorpresa representaban menos del 10 % entre ambos, por lo cual estos textos pasaron a formar parte de la categoría «SS/Otro», que también agrupó a los *tweets* que no expresaban sentimientos (podía tratarse de un aviso o noticia). Por otro lado, como la clase ampliamente mayoritaria fue felicidad, se realizó un submuestreo aleatorio, con el riesgo de perder información relevante, pero asegurando el equilibrio entre las categorías consideradas (Longadge & Dongre, 2013).

Finalmente, los *tweets* utilizados como base del aprendizaje fueron 498, categorizados según se observa en la Tabla 1.

Tabla 1: *Tweets* etiquetados

Sentimiento	Cantidad	Porcentaje
Asco	106	21,3%
Felicidad	108	21,7%
Ira	82	16,5%
Tristeza	101	20,3%
SS/Otro	101	20,3%
Total	498	

Clasificación con aprendizaje automático

La representación de textos, frecuentemente utilizada, es el modelo vectorial, que consiste en caracterizar cada documento por las palabras y ocurrencias que aparecen en él. En este trabajo se utilizó el enfoque de ponderación *Term frequency – Inverse document frequency* (Tf-Idf) (Manning, Raghavan, & Schütze, 2008). Esta técnica deja de lado algunas combinaciones de palabras que pueden aparecer a menudo en el corpus y que tienen mayor significancia que si aparecieran en forma separada, por ejemplo, «*por favor*» o «*buen día*». Por esta razón también se consideró estructurar los textos con *n*-gramas, de tal forma de obtener no solo palabras, sino además secuencia de *n* palabras consecutivas que permiten mantener y respetar el orden en el que aparecen escritas. Se experimentó con *n*=1, *n*=2 y *n*=3. De esta forma cada mensaje (*tweet*) se convierte en una representación adecuada para los algoritmos de aprendizaje automático.

El aprendizaje semisupervisado es una técnica del aprendizaje automático que consiste en etiquetar un conjunto de datos no etiquetados a partir de otro conjunto menor de datos etiquetados (Witten, Hall, Frank, & Pal, 2017). Los ejemplos etiquetados se usan para aprender modelos que caractericen cada clase o categoría, y los ejemplos sin etiqueta se usan para refinar los límites entre las clases (Han, Kamber, & Pei, 2012). Los algoritmos semisupervisados son atractivos para utilizar en aquellos casos donde el etiquetado es muy costoso y requiera tiempo o intervención humana. En Abudalfa & Ahmed (2019), se evaluaron una serie de algoritmos semisupervisados aplicados a textos de micro-blogs y en idioma inglés, y se concluyó que este enfoque es relevante para la clasificación textual.

En esta etapa se aplicó el método *self-training*, que es una de las formas más simples de clasificación semisupervisada: primero se construye un clasificador usando los datos etiquetados y luego el clasificador categoriza los datos no etiquetados. Solo los nuevos ejemplos etiquetados con una confianza que supere cierto umbral se anexan al conjunto etiquetado y el proceso de aprendizaje se repite (Han *et al.*, 2012) hasta que no queden ejemplos sin etiquetar o ninguno supere el umbral estipulado.

En este trabajo, se usaron los 498 ejemplos etiquetados manualmente y 10000 ejemplos pre-procesados, como fue explicado en la sección Preparación. Como variante del método, en lugar

de un algoritmo clasificador, participaron dos. En la etapa iterativa, los ejemplos en los cuales ambos algoritmos asignaron la misma categoría y que además superaron el 80 % de confianza en la categorización se agregaron al conjunto de entrenamiento y se eliminaron del conjunto de datos no etiquetados.

Los algoritmos clasificadores fueron seleccionados previamente a partir de una serie de pruebas con un conjunto de algoritmos tradicionales de clasificación y distintas cantidades de atributos. Naive Bayes y Support Vector Machine (SVM) resultaron los de mejor *performance* entrenados con 500 atributos. Naive Bayes logró 0,76 de *recall* y 0,79 de precisión, y SVM logró 0,79 de *recall* y 0,82 de precisión. Para ambos algoritmos, la métrica F1, que combina ambas medidas, resultó la de mayor valor entre todas las pruebas.

Luego, en el proceso semisupervisado, fueron suficientes 16 iteraciones para clasificar 8403 ejemplos inicialmente no etiquetados. La distribución de las categorías asignadas por los modelos se observa en la Tabla 2. La validación del método se realizó inspeccionando los mensajes y se comprobó que alrededor del 5 % les fue asignada una etiqueta errónea.

Tabla 2: Resultados clasificación semisupervisada

Emoción	Cantidad	Porcentaje
Asco	134	0.2%
Felicidad	6286	79.5%
Ira	670	1.8%
Tristeza	516	1,0%
SS/Otro	797	17.5%
Total	8403	

De esta forma se obtuvo un corpus con una cantidad mayor de mensajes clasificados que el del corpus inicial.

Clasificación con diccionarios léxicos

Para esta investigación se utilizaron dos diccionarios: el NRC VAD Lexicon (Mohammad, VAD, 2018) y el NRC Emotion Lexicon (Mohammad & Turney, 2013). El primero tiene más de 20.000 palabras y cada palabra tiene un puntaje de valencia (V), activación (A) y dominancia (D) que varía entre 0 (V, A o D más bajo) y 1 (V, A o D más alto). El segundo diccionario tiene más de 14.000 palabras con ocho emociones (ira, miedo, anticipación, confianza, sorpresa, tristeza, alegría y asco). Las palabras de ambos *datasets* están en inglés pero cuentan con traducción a varios idiomas, entre ellos el español. Se combinaron los dos diccionarios para los pasos siguientes.

Las palabras de los diccionarios se ubicaron en el espacio de dimensiones VAD, lo que determinó las zonas o grupos de cada emoción, y mostró así que las palabras asociadas a una misma emoción, en general, tienen valores VAD similares. Los puntos medios, en ese espacio de tres dimensiones, de cada agrupamiento de palabras de cada emoción fueron denominados centroides. La Tabla 3 detalla los valores medios de cada dimensión y los respectivos valores de desviación estándar.

Tabla 3: Centroides

	Valencia		Activación		Dominancia	
	M	D	M	D	M	D
Felicidad	0,640	0,229	0,526	0,177	0,595	0,159
Asco	0,229	0,170	0,627	0,172	0,410	0,149
Ira	0,242	0,177	0,676	0,166	0,477	0,162
Tristeza	0,226	0,175	0,591	0,183	0,393	0,156

M: media. D: desviación estándar

En la Figura 2 se muestra la ubicación de los centroides en el espacio de dimensiones VAD. El centroide (0.32, 0.32, 0.32) de la categoría SS/Otro, que representa textos sin emoción o con otro sentimiento no analizado, se obtuvo empíricamente. Este punto se considera aceptable si se tiene en cuenta que no solo representa textos sin emoción o neutros, sino que, además, no está

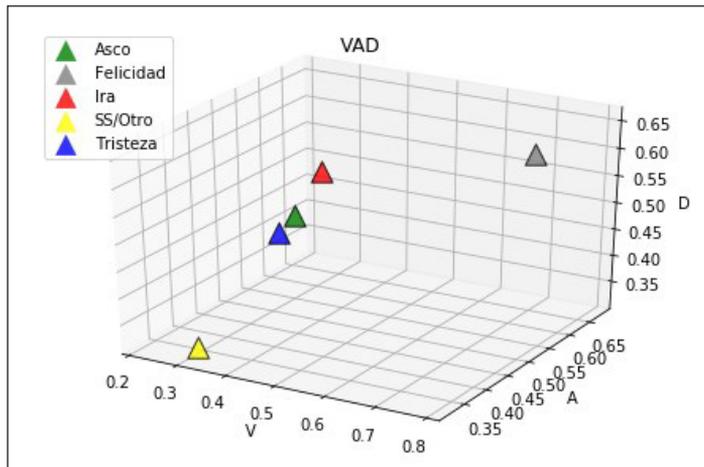


Figura 2: Centroides

tan lejano del punto (0.5, 0.5, 0.5), considerado como centroide neutro en algunos trabajos como Kim, Valitutti & Calvo (2010).

Para determinar la polaridad de las oraciones es común sumar o calcular el promedio de los puntajes de las palabras que componen el mensaje (Kolchyna, Souza, Treleanven, & Aste, 2015). Siguiendo un criterio similar, se optó por el cálculo del promedio para la clasificación de los *tweets*, pero teniendo en cuenta que las puntuaciones están formadas por tres valores. Es decir, el valor VAD de cada frase se calcula promediando los valores VAD de cada una de las palabras (Kim, Valitutti, & Calvo, 2010). De esta manera, cada *tweet* tiene también asociado los valores VAD y puede pensarse como un punto en el espacio de las tres dimensiones.

5. Resultados

Con los valores VAD asignados a cada *tweet* (un punto en el espacio) se calculan las distancias a cada uno de los centroides mediante la fórmula de cálculo de distancia Euclídea entre dos puntos (Witten, Hall, Frank, & Pal, 2017). Finalmente, la emoción del *tweet* la determina el centroide más cercano, es decir, se encuentra en el mismo grupo de palabras asociadas a la emoción.

En esta etapa se utilizaron 4612 mensajes clasificados automáticamente en la etapa previa, de los cuales 3446 coincidieron en la clasificación por aproximación a un centroide. Esto representa el 74,50 % de aciertos. En la Tabla 4 se puede observar la *performance* del método en cuanto a precisión y *recall*. Los mejores resultados los obtiene la emoción Felicidad.

Tabla 4: Resultados

Emoción	Precision	Recall
Ira	23,20%	16,73%
Felicidad	86,87%	95,37%
Asco	38,78%	9,05%
Tristeza	45,26%	21,88%
SS/Otro	7,52%	11,92%

Este enfoque presenta algunas debilidades, entre ellas se pueden detallar las siguientes:

- un gran número de palabras del corpus no se encontró en los diccionarios, por lo cual no fueron parte del cálculo VAD de los *tweets* donde aparecían.

- en el corpus existen palabras coloquiales o del lunfardo, y si bien algunas forman parte del diccionario NRC VAD, tienen una significación diferente o contraria a la emoción representada.

- algunas palabras del diccionario de emociones formaron parte del cálculo de más de un centroide por estar asociadas a más de una emoción.

6. Conclusiones

Los sentimientos o emociones expresados de manera textual pueden contener información importante para revelar el estado de ánimo, interés o desagrado de una persona ante un evento o producto. El aumento de comentarios y opiniones emitidas en redes sociales, blogs y portales de noticias incrementa el interés en el campo del análisis de sentimientos. Por la ambigüedad del lenguaje, el descuido en la escritura y las nuevas formas de lenguajes, el procesamiento de los datos textuales conlleva un trabajo arduo para obtener datos normalizados y apropiados para cualquier forma de aprendizaje o análisis.

En este trabajo se utilizaron textos extraídos de la red social Twitter, emitidos en la Argentina. Durante el procesamiento de los *tweets*, se observó que contenían características que dificultarían el análisis posterior, lo cual llevó a realizar un proceso de extracción y transformación de estos.

Ante la falta de un gran corpus de textos etiquetados con emociones fue necesario crear uno para los experimentos. La clasificación inicial y manual por parte de etiquetadores humanos resultó en un proceso arduo y complejo que produjo alrededor de 500 *tweets* asociados a una emoción. Las emociones consideradas fueron cuatro: ira, felicidad, asco y tristeza, y se agregó una quinta categoría para los *tweets* que no expresaban sentimientos o expresaban alguno no contemplado.

Estos textos fueron parte del método, primero supervisado y luego semisupervisado, que generó un corpus de textos etiquetado. Los algoritmos implementados se mantuvieron por encima del 90 % de efectividad, se lograron clasificar más del 80 % de los ejemplos sin categoría. En la etapa de aprendizaje con diccionarios se combinaron dos con más de 14000 palabras y con los puntajes de las dimensiones emocionales valencia, activación y dominancia. Se determinó el valor emocional de cada *tweet* a partir de la distancia al centroide más cercano o representativo. Se utilizaron 4612 *tweets* clasificados previamente y se obtuvieron alrededor de 75 % de aciertos, lo que demuestra que el método empleado es aceptable.

Del análisis de errores se concluye que el método de clasificación con diccionarios léxicos podría obtener mejores resultados si contuvieran palabras o expresiones usadas en nuestro país y que fueran frecuentes en el corpus utilizado, por lo cual desarrollar un diccionario VAD argentino queda propuesto para un trabajo futuro y eventuales investigaciones.

En este artículo se presentó la primera parte de la investigación en el área de análisis de sentimientos en textos. Se pretende continuar la línea de investigación en datos textuales, profundizando en el campo de la detección de emociones en redes sociales y posiblemente en otras fuentes de datos.

Referencias

- Abudalfa, S., & Ahmed, M. (2019). Semi-Supervised Target-Dependent Sentiment Classification for Micro-Blogs. *Journal of Computer Science and Technology*, 19(1). doi:<https://doi.org/10.24215/16666038.19.e06>
- Amor, M., Monge, A., Talamé, L., & Cardoso, A. (2019). Clasificación de sentimientos en opiniones de una red social basada en dimensiones emocionales. *7º Congreso Nacional de Ingeniería en Informática/Sistemas de Información*. Buenos Aires: CONAIIISI.

- Baccianella, S., Esuli, A., & Sebastiani, F. (2010). SentiWordNet 3.0: An Enhanced Lexical Resource for Sentiment Analysis and Opinion Mining. *International Conference on Language Resources and Evaluation, LREC 2010*. Valletta, Malta.
- Blog Master Data Science. (Junio de 2019). *Universidad de Alcalá*. Recuperado de <https://www.master-data-scientist.com/lenguajes-programacion-data-science/>
- Bradley, M. M., & Lang, P. J. (1999). Affective Norms for English Words (ANEW): Instruction Manual and Affective Ratings. *Technical report C-1, the center for research in psychophysiology*, 30(1), 25-36.
- Dharmadhikari, S., Ingle, M., & Kulkarni, P. (2012). Analysis of semi supervised learning methods towards multi label text classification. *International Journal of Computer Applications*, 42(16), 15-20.
- Diaz Rangel, I., Sidorov, G., & Suarez Guerra, S. (2014). Creación y evaluación de un diccionario marcado con emociones y ponderado para el español. *Onomazein. Revista semestral de lingüística, filología y traducción*, 31-46.
- Ekman, P. (1972). *Emotion in the human face: guidelines for research and an integration of findings*. New York: Pergamon.
- Han, J., Kamber, M., & Pei, J. (2012). *Data Mining: Concepts and Techniques*. USA: Morgan Kaufmann Publishers.
- Kemp, S. (2019). *DataReportal*. Recuperado de <https://datareportal.com/reports/digital-2019-global-digital-overview>
- Kim, S. M., Valitutti, A., & Calvo, R. A. (2010). Evaluation of unsupervised emotion models to textual affect recognition. *Proceedings of the NAACL HLT 2010 Workshop on Computational Approaches to Analysis and Generation of Emotion in Text* (págs. 62-70). Los Angeles, California.
- Kolchyna, O., Souza, T. T., Treleanven, P. & Aste, T. (2015). Methodology for Twitter Sentiment Analysis. *arXiv preprint arXiv:1507.00955*.
- Longadge, R., & Dongre, S. (2013). Class imbalance problem in data mining review. *International Journal of Computer Science and Network (IJCSN)*. Recuperado de arXiv preprint arXiv:1305.1707
- Manning, C. D., Raghavan, P., & Schütze, H. (2008). *Introduction to information retrieval*. Cambridge University Press.
- Miranda, C. H., Guzmán, J., & Salcedo, D. (2016). Minería de Opiniones basado en la adaptación al español de ANEW sobre opiniones acerca de hoteles. *Procesamiento del Lenguaje Natural*(56), 25-32. Recuperado de <https://www.redalyc.org/articulo.oa?id=515754423002>
- Mohammad, S. M. (2018). Obtaining reliable human ratings of valence, arousal, and dominance for 20,000 English words. *Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics* (págs. 174-184). Melbourne, Australia: Association for Computational Linguistics. doi:10.18653/v1/P18-1017
- Mohammad, S. M. & Turney, P. D. (2010). Emotions evoked by common words and phrases: Using mechanical turk to create an emotion lexicon. En A. f. Linguistics (Ed.), *Proceedings of the NAACL HLT 2010 workshop on computational approaches to analysis and generation of emotion in text* (págs. 26-34). Los Angeles, CA: Association for Computational Linguistics.

- Recuperado de <https://www.aclweb.org/anthology/W10-0204>
- Mohammad, S. M., & Turney, P. D. (2013). Crowdsourcing a word-emotion association lexicon. *Computational Intelligence*, 29(3), 436-465. doi:<https://doi.org/10.1111/j.1467-8640.2012.00460.x>
- Padró, L., & Stanilovsky, E. (2012). FreeLing 3.0: Towards Wider Multilinguality. *Proceedings of the Language Resources and Evaluation Conference (LREC 2012)*. Istanbul, Turkey: ELRA.
- Qi, P., Dozat, T., Zhang, Y., & Manning, C. D. (2018). Universal Dependency Parsing from Scratch. *Proceedings of the {CoNLL} 2018 Shared Task: Multilingual Parsing from Raw Text to Universal Dependencies* (págs. 160-170). Brussels, Belgium: Association for Computational Linguistics. Recuperado de <https://nlp.stanford.edu/pubs/qi2018universal.pdf>
- Redondo, J., Fraga, I., Padrón, I. & Comesaña, M. (2007). The Spanish adaptation of ANEW (Affective Norms for English Words). *Behavior Research Methods*, 39(3), 600-605. doi:10.3758/BF03193031
- Selva Castelló, J. (2015). *Desarrollo de un sistema de análisis de sentimiento sobre Twitter*. Universitat Politècnica de València Escuela. Recuperado de <http://hdl.handle.net/10251/55471>
- Talamé, L., Cardoso, A. & Amor, M. (2019). Comparación de herramientas de procesamiento de textos en español extraídos de una red social para Python. *Simposio Argentino de Inteligencia Artificial (ASAI)*. Salta.
- Twitter. (s.f.). *Developer*. Recuperado de <https://developer.twitter.com/>
- Witten, I., Hall, M., Frank, E., & Pal, C. (2017). *Data Mining: Practical Machine Learning Tools and Techniques*. Amsterdam: Morgan Kaufmann.

Alejandra Carolina Cardoso

Licenciada en Ciencias de la Computación (Universidad Nacional del Sur, Bahía Blanca). Máster en Informática (Universidad del Norte Santo Tomás de Aquino, Tucumán). Docente e investigadora de la Facultad de Ingeniería de la Universidad Católica de Salta. Participa en proyectos de investigación sobre minería de datos y minería de textos. Coautora de artículos sobre la misma temática. Integra el Grupo de Análisis de Datos del Instituto de Estudios Interdisciplinarios de Ingeniería (I.Es.I.Ing.) de UCASAL.

Identificador ORCID: <https://orcid.org/0000-0003-3218-1072>

acardoso@ucasal.edu.ar

María Lorena Talamé

Licenciada en Análisis de Sistemas (Universidad Nacional de Salta). Máster Universitario en Ingeniería Informática de la Universidad Abierta de Cataluña. Se desempeña como docente de la carrera de Ingeniería en Informática de la Universidad Católica de Salta. Imparte cursos de robótica y es coautora de artículos sobre la temática. Pertenece al Grupo de Análisis de Datos del Instituto de Estudios Interdisciplinarios de Ingeniería (I.Es.I.Ing.) de UCASAL.

Identificador ORCID: <https://orcid.org/0000-0003-3224-0124>

mltalame@ucasal.edu.ar

Matías Nicolás Amor

Ingeniero en Informática, Universidad Católica de Salta, Salta. Investigador del Grupo de Análisis de Datos del Instituto de Estudios Interdisciplinarios de Ingeniería (I.Es.I.Ing.) de la Facultad de Ingeniería de la Universidad Católica de Salta. Participa en proyectos de investigación sobre informática forense.

Identificador ORCID: <https://orcid.org/0000-0003-0561-1815>

mnamor@ucasal.edu.ar

Agustina Monge

Ingeniera en Informática, Universidad Católica de Salta. Desarrolladora en una empresa de *software*. Forma parte del Grupo Análisis de Datos del Instituto I.Es.I.Ing de la Facultad de Ingeniería

agum_96@hotmail.com