

Detección de ansiedad mediante minería de texto en la era de redes sociales: Revisión bibliográfica

Anxiety Detection using Text Mining in the Social Network Era: A Literature Review

Valeria Torres ^a, Orlando Erazo ^b

Abstract:

Mental disorders are increasingly common, mainly anxiety. This disorder, when not detected in time, can become something serious, leading to extremes such as suicide. However, since several people who suffer from it opt for online interaction, there is the possibility of resorting to text mining focused on social networks. In this sense, with the present work we sought to review the bibliography that reports studies employing text mining to determine the users who suffered from anxiety through their publications or comments on their social networks. The review was organized based on the phases of text mining; that is, data collection, preprocessing, and classification. Among the aspects to be highlighted are (i) the tendency to use a social network to obtain data, especially Twitter; (ii) the relevance of data cleaning, applying techniques such as lemmatization; (iii) the most prominent algorithms in anxiety detection, such as Naive Bayes, logistic regression, SVM, and random forest. Beyond the contributions of the reviewed articles, it can be noted that there is still a need to develop more models that detect the disorder of interest.

Keywords:

Anxiety, text mining, social networks, machine learning

Resumen:

Los trastornos mentales son cada vez más comunes, principalmente la ansiedad. Este trastorno, al no ser detectado a tiempo, puede volverse algo grave llevando a extremos como el suicidio. Sin embargo, dado que varias personas que lo padecen optan por la interacción en línea, existe la posibilidad de recurrir a la minería de texto enfocada a redes sociales. En este sentido, con el presente trabajo se buscó revisar la bibliografía que reporte estudios empleando minería de texto para determinar los usuarios que padecían de ansiedad mediante sus publicaciones o comentarios en sus redes sociales. La revisión se organizó a partir de las fases de minería de texto; es decir, recopilación de datos, preparación o preprocesamiento y clasificación. Entre los aspectos a resaltar están (i) la tendencia a utilizar una red social para obtener datos, especialmente Twitter; (ii) la relevancia de la limpieza de datos, aplicando técnicas como *lemmatization*; (iii) los algoritmos más destacados en la detección de ansiedad, como *Naive Bayes*, regresión logística, SVM y *random forest*. Más allá de los aportes de los trabajos revisados, se puede notar que persiste la necesidad de desarrollar más modelos que detecten el trastorno de interés.

Palabras Clave:

Ansiedad, minería de texto, redes sociales, aprendizaje automático

Introducción

Según la Organización Mundial de la Salud (OMS), una de cada ocho personas en el mundo padece un trastorno mental, siendo los más comunes los trastornos de ansiedad y depresión [1]. El trastorno de ansiedad es una enfermedad mental, que tiene el grupo más alto de carga social e individual de desórdenes mentales [2]. Aunque la

ansiedad es uno de los trastornos más comunes, es muy poco detectado, lo cual evita que las personas reciban ayuda o tratamiento provocando síntomas severos [3]. Algunos estudios muestran que las personas que padecen este trastorno suelen ver las situaciones sociales como amenazantes, lo cual hace que puedan mostrar una preferencia por la interacción en línea sobre las interacciones cara a cara [4], [5].

^a Autor de Correspondencia, Universidad Técnica Estatal de Quevedo, <https://orcid.org/0000-0001-8778-2794>, Email: valeria.torres2017@uteq.edu.ec

^b Universidad Técnica Estatal de Quevedo, <https://orcid.org/0000-0001-5642-9920>, Email: oerazo@uteq.edu.ec

Debido a la gran interacción de las personas en línea, las redes sociales han aportado datos en tamaño, diversidad, capacidad y calidad [6]. Aquí entra en juego la minería de texto. Esta, en redes sociales, permite la obtención de datos, ya que los usuarios suelen publicar texto, imágenes solas o junto con texto en sus mensajes, publicaciones y comentarios [7]. Basado en esto, varios estudios han podido medir la tendencia de la depresión y la ansiedad a través de las redes sociales utilizando técnicas de minería de texto de redes sociales como Facebook, Twitter, Reddit y Weibo. El uso de estas técnicas ha permitido detectar a los usuarios que tienen ansiedad mediante el análisis del texto publicado verificando la relación entre este y las palabras relacionadas al trastorno de ansiedad.

Aunque existen varios estudios relacionados a la detección de la ansiedad, pocos de estos se centran específicamente en este trastorno, lo cual limita la detección de más de un tipo de ansiedad que existe según la OMS. Debido a esto, no se puede predecir si la enfermedad pertenece a un tipo específico, lo cual puede conllevar a afectaciones físicas. También, la falta de extracción de datos de redes sociales en conjunto limita los resultados de la minería de texto, impidiendo el realizar una comparación de resultados y teniendo una menor precisión de estos.

Con base en lo expuesto, en este artículo se busca revisar la literatura referente a la detección de la ansiedad mediante minería de texto. Para ello, se recopiló artículos recientes que se centran en la minería de texto de redes sociales populares en la actualidad para obtener información de una mayor cantidad de usuarios. La selección de artículos se efectuó tomando en consideración aquellos trabajos que reportaron mejor desempeño en la predicción y los que se basaban en una mayor cantidad de extracción de datos.

La organización de los trabajos y su revisión se realizó considerando las tres etapas principales que se siguen en este tipo de estudios. Se inicia con la fase de recopilación de datos para obtener la información que ayudará a la detección de trastornos de ansiedad mediante minería de

texto. Luego, se continúa con el procesamiento de datos, etapa en la que se limpian los datos obtenidos en la fase previa. Por último, en la fase para clasificar datos se usan algoritmos de clasificación para detectar a los usuarios que padecen de trastorno de ansiedad. Así, la Figura 1 ilustra este proceso junto con algunas de las principales ideas encontradas en la revisión.

Recopilación de datos

La recopilación de datos se utiliza para extraer conocimientos o patrones de interés del estudio [8]. Los datos recolectados en esta fase se utilizan para entrenar la máquina. Se pueden utilizar varios tipos de datos para el entrenamiento como: algoritmos de aprendizaje basados en cuestionarios, entrevistas, datos demográficos, registros médicos de salud, historial de tratamiento, y escalas de calificación de ansiedad [9]. Además de este tipo de datos, recientemente los investigadores también están utilizando datos registrados en publicaciones de redes sociales, para obtener información sobre los sentimientos de los usuarios [9]. Estos datos permiten que la información sea actual y que los conjuntos de datos sean de una mayor cantidad de usuarios.

Chang y Tseng [10] recopilaron datos de entrenamiento y prueba, reclutando a más de 200 usuarios de redes sociales en línea, a los cuales les solicitaron llenar un cuestionario de escala. También rastrearon los datos de Facebook de los participantes para realizar el entrenamiento y prueba del algoritmo de aprendizaje automático. Para lograr una mayor precisión en los resultados del algoritmo de aprendizaje planteado, en este mismo trabajo los autores proponen rastrear datos de otras redes sociales.

Con fines similares, Ávila, Altamirano, Ávila y Guerrero [11] utilizaron una página web desarrollado por ellos. En esta página los usuarios dan permiso para obtener sus datos (foto, nombre, email, publicaciones). Una vez que el

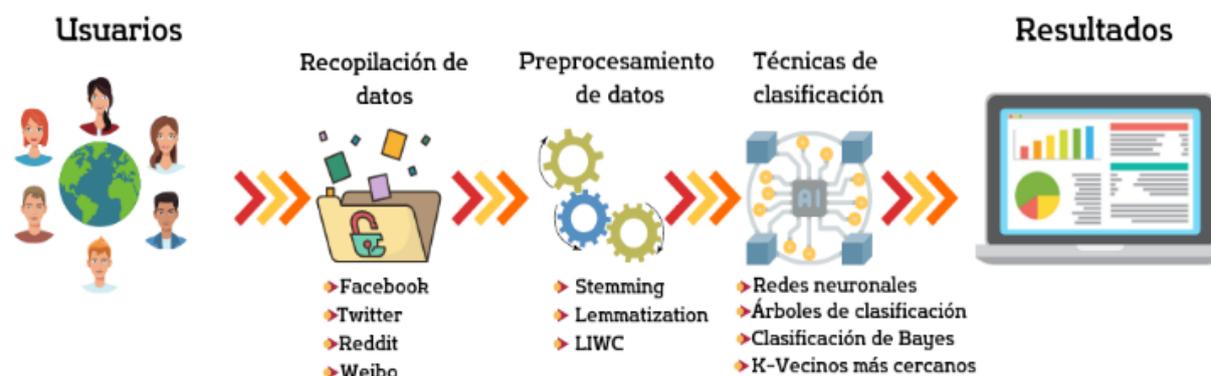


Figura 1. Organización del documento y aspectos relevantes

usuario se registra en la página web con su cuenta de Facebook e inicia sesión, debe realizar una prueba de ansiedad (AMAS-C en este caso). Después de que el usuario completa la prueba, los autores evalúan las publicaciones de los usuarios para comparar y analizar cuatro aspectos: número de publicaciones, publicaciones agrupadas en neutro, publicaciones agrupadas en negativas, publicaciones agrupadas en positivas. Esta agrupación permite mostrar si las publicaciones de los usuarios son negativas positivas y neutras para así facilitar la visualización de la información.

De una manera distinta, Gupta y Kaushik [12] emplearon la red social Twiter. Ya que esta red social es muy usada para expresar emociones por parte de los usuarios, a diferencia de lo mencionado anteriormente, los autores utilizaron APIs de Twitter como: Streaming API, RESTAPI, Search API. Estas tecnologías, permitieron realizar la búsqueda de palabras que puedan incitar al suicidio por trastornos de ansiedad y bipolaridad. Para realizar estos análisis es necesario efectuar también un estudio de las palabras o comentarios que puedan indicar que un usuario tiene ansiedad leve, no solo una etapa avanzada que pueda ya indicar de casos más graves como el suicidio.

Asimismo, Zhao [13] utilizó Twitter para recopilar los datos para su estudio, aunque el enfoque comenzó con la recopilación de tuits relevantes para la discusión de temas relacionados con *sexual and gender minority (SGM)*, determinando *tweets* de autoidentificación y usuarios de Twitter SGM. Luego, Zhao determinó estados emocionales de estos usuarios a través del análisis de texto. Dentro de los estados emocionales, Zhao buscó señales relacionadas con la salud mental como emociones negativas, ira y ansiedad, para poder predecir mediante minería de texto los usuarios de Twitter que pueden presentar cuadros de ansiedad.

En otro estudio, Wang, Zhao, Bian y Zhang [14] también utilizaron Twiter para esta fase, la cual consistió en la búsqueda de tuits sobre cinco ingredientes de suplementos dietéticos. Luego de esto, los investigadores compararon la frecuencia de las palabras de desorden mental mencionadas y los sentimientos en los tuits publicados antes y después del uso de suplementos. Adicionalmente, ellos optaron por comparar las emociones positivas y negativas, de ira, ansiedad y tristeza reflejadas en los tuits. Las emociones positivas y negativas indican los estados emocionales generales del usuario, mientras que las emociones de ira, ansiedad y tristeza pueden considerarse de ansiedad, depresión y trastornos del estado de ánimo del usuario. Esta clasificación de emociones es esencial para identificar los usuarios propensos a tener trastorno de ansiedad.

De una manera similar se encuentra el trabajo de Larsen, Boonstra, Batterham, O'Dea, Paris y Christensen [15] también basado en la red social Twitter. Sus autores

construyeron el sistema "We Feel" para analizar en tiempo real el sentimiento emocional expresado en Twitter. Los tuits obtenidos fueron clasificados en emociones primarias y secundarias para poder detectar los sentimientos de ellos. Además, estos autores implementaron la localización de los usuarios, lo cual fue de ayuda para mostrar la información obtenida de manera interactiva.

Otro trabajo que también empleó Twitter fue el de Gruda y Hasan [16]. Estos autores tuvieron un conjunto de datos de 10.510 tuits relacionados con los términos de búsqueda. Además, en este trabajo se tomó en cuenta *retweets* y respuestas de publicaciones, lo cual hizo que el contenido se repitiera en algunas ocasiones, aunque el objetivo de los tuits haya sido distinto.

Por otro lado, para obtener información tanto de las publicaciones como de los comentarios de los usuarios, Tariq [17] utilizó Python (API) para Reddit y PRAW para descargar las 3922 publicaciones y cinco comentarios de cada publicación de cada uno de los siguientes *subreddits* como: depresión, ansiedad, trastorno por déficit de atención con hiperactividad (TDAH) y bipolar. Sin embargo, una similitud con el estudio de Chang y Tseng [3] y el de Gupta y Kaushik [12] radica en que hacen el análisis basándose solo en una red social de todas las existentes. Esto minimiza la garantía de una detección a tiempo del trastorno de ansiedad en muchos usuarios.

Mientras tanto, Ta, Li, Yang, Jiao, Talg y Li [18] usaron una red social distinta, que en este caso fue Weibo. Adicionalmente, estos investigadores también tomaron datos de la red social Twitter, tal como se ha mencionado en otros trabajos ([12]–[14]). De la red social Weibo, estos autores obtuvieron información de mensajes de perfiles públicos y aplicaron un cuestionario de manera anónima *Self-Rating Anxiety Scale (SAS)* [19]. Ellos tomaron una pequeña muestra de mensajes categorizándolos por arte, entretenimiento, examen, películas, público, deportes y juegos. En cambio, para el conjunto de datos tomado de Twitter solo se tomó en cuenta una categoría temática, la cual en este caso fue COVID o hashtags relacionados como, #2019nCov, #CoronaOutbreak, #Coronavirus. Aunque se usaron dos redes sociales para obtener el conjunto de datos, las temáticas fueron distintas, siendo lo recomendable que en ambos conjuntos de datos se tengan en cuenta las mismas categorías temáticas.

Preprocesamiento de datos

La siguiente etapa contemplada en esta revisión es el preprocesamiento de datos, la cual es esencial para mejorar la eficiencia de los datos [20]. Se trata de uno de los pasos importantes de la minería de texto, ya que se ocupa de la preparación y transformación del conjunto de datos buscando al mismo tiempo hacer que el descubrimiento de conocimiento sea más eficiente [20].

Su ejecución requiere de la utilización de herramientas como *stemming*, *lemmatization* y *Natural Language Toolkit (NLTK)*. El *stemming* consiste en convertir una palabra en raíz eliminando el prefijo de la frase [21]. La *lemmatization* por su parte trata sobre encontrar la forma morfológica base (lema) de una palabra [22]. NLTK se encarga de diversas tareas de *Natural Language Processing (NLP)*, por ejemplo, la *tokenization* y el *stemming* [23]. Con estas herramientas u otras similares es posible procesar el conjunto de datos que se obtenga de redes sociales.

El procesamiento de datos puede encontrarse explícitamente en diferentes trabajos. Tadesse et al. [24] utilizaron las herramientas de NLP para preprocesar el conjunto de datos antes de pasar a la fase de selección de características y entrenamiento. En primer lugar, utilizaron la tokenización para dividir los mensajes en tokens individuales. Luego, estos autores eliminaron todas las URL, puntuaciones y palabras vacías o *stop words* que podrían dar lugar a resultados erráticos si no se tienen en cuenta. Por último, aplicaron el *stemming* para reducir las palabras a su raíz y agrupar palabras similares [24]. Esto ayuda a que el resultado de la técnica de clasificación que se aplique sea más preciso.

Asimismo, Meshran et al. [25] utilizaron *stemming* para el procesamiento de datos. Estos autores obtuvieron los datos de Twitter, eliminaron las palabras vacías y emplearon *stemming* para reducir el conjunto de palabras. Luego aplicaron el etiquetado part-of-speech (POS) a los archivos de palabras vacías y a las raíces de palabras eliminadas, para finalmente utilizar las técnicas de clasificación y obtener resultados eficaces [26].

Por su lado, Tyshchenko [27] realizó el preprocesamiento limpiando los datos de entrada utilizando expresiones regulares, que son en realidad las secuencias de caracteres que definen la cadena de búsqueda en un texto. Hay que tener presente a esta limpieza de datos como un paso importante para obtener resultados fiables. Luego, este mismo autor escribió los mensajes en minúsculas y fueron guardados en archivos de texto independientes para poder realizar el preprocesamiento una sola vez y reducir así considerablemente el tiempo total de ejecución. A diferencia del estudio de Meshran et al. [25], Tyshchenko eligió la *lemmatization* porque, a diferencia del *stemming*, pretendía eliminar las terminaciones de las palabras basándose en el vocabulario y en el análisis morfológico de ellas para que las palabras derivadas de otras sean analizadas como un mismo elemento.

En otros trabajos también se realiza una limpieza de datos como parte del preprocesamiento. Ma et al. [28] limpiaron su conjunto de datos; en general, se concentraron en los caracteres especiales, etiquetas retuit y la dirección de enlace. Luego, eliminaron las palabras vacías y signos de

puntuación mediante una lista de palabras reservadas recopiladas de internet. Cabe notar que las *non-words* (varias letras que parecen una palabra, pero que no se acepta como tal) son muy comunes en los datos de redes sociales debido a errores tipográficos o acrónimos, como "lol" (de *Laugh out loud*). Estas palabras fueron filtradas con el conjunto de herramientas NLTK. Así, el uso de esta herramienta permitió limpiar las *non-words* del conjunto de datos obtenido, lo cual minimizó el conjunto de datos para que el resultado final sea más preciso.

Por otro lado, Islam et al. [29] después de recolectar datos de Facebook, los limpiaron para evitar cualquier inconsistencia y luego los analizaron con el software LIWC (www.liwc.app), el cual permite procesar el texto línea a línea. El conjunto de datos de estos autores contiene un total de 21 columnas, donde 13 columnas representan la información de estilo lingüístico (artículos, preposiciones, verbos auxiliares, conjunciones, pronombre personal, pronombres impersonales, verbos, negación, etc.), 5 columnas representan la información emocional (positiva, negativa, triste, ira y ansiedad), 3 columnas representan la información del proceso temporal (pasado, presente y futuro). Cada columna del conjunto de datos brinda información individual sobre el comportamiento depresivo de cada usuario. Al final, el análisis con el software LIWC permitió cuantificar el uso de palabras en clasificaciones mentalmente significativas.

Técnicas de clasificación

En la tercera etapa se contemplan las técnicas de clasificación, que se refieren a determinar si un documento pertenece o no a una categoría dada, observando las palabras o términos de esa categoría [30]. Estas pueden dividirse en enfoques estadísticos y de aprendizaje automático o *Machine Learning (ML)*. Las técnicas estadísticas son procesos puramente matemáticos, por lo tanto, la necesidad de algoritmos que permitan la automatización es poco, lo contrario es para las técnicas de ML que se inventaron especialmente para la automatización [31].

Los algoritmos para realizar la clasificación de datos se dividen a grandes rasgos en categorías supervisadas, no supervisadas y semisupervisadas [31]. En la Figura 2 se muestra los algoritmos organizados de acuerdo con su clasificación.

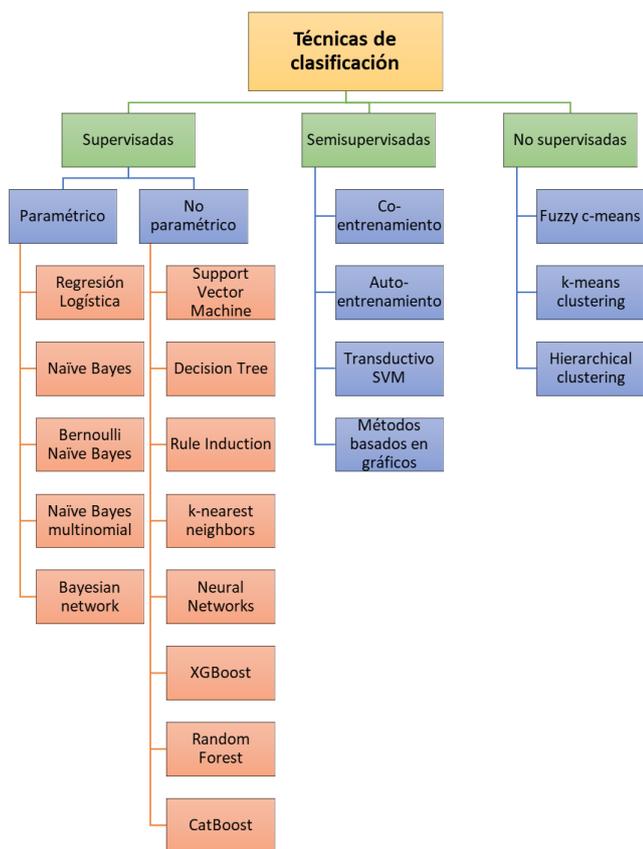


Figura 2. Técnicas de clasificación

Para clasificar los datos, Shen y Rudzicz [32] utilizaron la regresión logística (*LR*), una máquina de vector de soporte (*SVM*) y una red neuronal (*NN*) para la clasificación binaria. Los clasificadores *LR* y *SVM* se implementaron con SciKit-Learn (paquete de Python que incluye algoritmos de clasificación) [33]. Estos autores crearon una red neuronal personalizada de 2 capas con 256 unidades ocultas por capa y activaciones sigmoideas. Durante la optimización, utilizaron empíricamente un tamaño de lote de 500 y una tasa de aprendizaje de 0.01 para 200 iteraciones. En general, todos los algoritmos de clasificación son útiles, pero se obtuvo mayor precisión con la red neuronal personalizada. Sin embargo, los conjuntos de datos usados en este trabajo son relativamente pequeños y no están asociados con criterios, evaluaciones o registros de salud, para enfatizar la validez.

De manera similar, Swati et al. [34], utilizaron *LR*, pero también añadieron un clasificador de árbol de decisión y el algoritmo *XGBoost* [35]. Estos algoritmos de clasificación supervisados fueron usados para la categorización en cinco niveles de gravedad usando dos conjuntos de datos tomados de Twitter y de cuestionarios aplicados a usuarios. Para evaluar el rendimiento de los distintos clasificadores, estos autores calcularon la precisión de cada uno para ambos conjuntos de datos,

con lo cual se obtuvo una mayor precisión del clasificador *XGBoost*.

Tomando como conjunto de datos cuestionarios completados cara a cara con los usuarios, Palattao et al. [36] utilizaron cuatro algoritmos de clasificación. Los clasificadores que emplearon fueron *random forest*, *naïve bayes*, *SVM*, y *LR*. Con estos algoritmos de clasificación obtuvieron los porcentajes correspondientes de estrés, ansiedad y depresión presente en los conjuntos de datos obtenidos de los cuestionarios. Todos los algoritmos fueron probados con cuatro enfoques distintos, gracias a lo cual se concluyó que cuando se predice la presencia de una enfermedad mental, los resultados de la otra variable objetivo para el resto de las enfermedades mentales (en este caso, ansiedad y depresión) deben tomarse en cuenta.

Del mismo modo, Chadha y Kaushik [37] usaron diferentes algoritmos de aprendizaje como *bernoulli naïve bayes*, *naïve bayes multinomial*, árbol de decisión, *LR* y *SVM*. El objetivo de emplear estos algoritmos fue extraer características de los datos de Twitter, evaluar las medidas probabilísticas de los tuits y, a continuación, predecir el riesgo asociado a los datos. El resultado muestra que la regresión logística ofrece la mejor exactitud con un 79.65 %, una precisión con un 48.28 % y una recuperación muy baja con un 12.17 %.

Por otro lado, Priyaa et al. [38] aplicaron algoritmos de aprendizaje automático en el lenguaje de programación R utilizando RStudio. Los autores usaron los siguientes algoritmos de aprendizaje: árbol de decisión, *random forest*, *SVM*, *naïve bayes* y *K-nearest neighbour* (*K-NN*). Se obtuvo como resultado que la precisión de *naïve bayes* fue la más alta, aunque *random forest* resultó ser el mejor modelo en el global. Con esto, los autores lograron predecir el porcentaje de personas que sufren síntomas de estrés, ansiedad y depresión, de acuerdo con el nivel de gravedad.

En otro trabajo, Sau y Bhakta [39] usaron algunos de los algoritmos de aprendizaje automático empleados en trabajos citados previamente [31], [32], [34], [36]–[38]. Estos autores evaluaron varios algoritmos para resolver problemas de clasificación relacionados con la salud de manera eficiente. Los algoritmos evaluados fueron *bayesian network* (*BN*), *logistic*, *multiple layer perceptron* (*MLP*), *naïve bayes* (*NB*), *random forest* (*RF*), *random tree* (*RT*), *J48*, *sequential minimal optimisation* (*SMO*), *random sub-space* (*RS*), y *K Star* (*KS*). El resultado de esta evaluación fue que el algoritmo con mayor precisión es *random forest*.

Asimismo, Sau y Bhakta [40] evaluaron cinco algoritmos diferentes. Los algoritmos seleccionados fueron *CatBoost*, regresión logística, *SVM*, *naïve bayes* y *random forest*. Como resultado de esta evaluación el que tuvo mayor exactitud y precisión fue el algoritmo *CatBoost* con una

precisión predictiva del 89.3 %. El algoritmo que siguió a *CatBoost* fue el de regresión logística con una precisión predictiva de 87.5 %.

En un trabajo más reciente, Kumar et al. [41] usaron los algoritmos *NB*, *BN*, *k-star*, *local nearest neighbor (LNN)*, *MLP*, *radial basis function network (RBFN)*, *random forest (RF)* y *J48*. Los ocho algoritmos pertenecen a cuatro amplias categorías: *bayes classification*, *K-nearest neighbor*, *neural network* y *Tree-based classification*. Después de la aplicación de todas las técnicas, los resultados mostraron que las redes neuronales se desempeñaron mejor que el resto de las categorías. Entre la categoría de redes neuronales, RBFN se desempeñó mejor para depresión. Sin embargo, el resultado del RF es cien por ciento para ansiedad

Discusión

El trastorno de ansiedad se ha vuelto un trastorno mental común entre las personas. Su detección a tiempo es importante para evitar que los síntomas sean mayores y lleven a las personas a tomar decisiones que afecten su vida. Muchas de las personas que padecen este trastorno prefieren la interacción en línea. Debido a esto, una buena manera de detectar a los usuarios que están en esta condición es usar la minería de texto basada en la información que muestran en sus redes sociales. Sin embargo, a pesar de los estudios realizados y revisados en este trabajo, pocos se enfocan en esta enfermedad en específico o a su vez no usan todas las redes sociales en conjunto para analizar las publicaciones y comentarios. Tratando de ilustrar algunos de los aspectos abordados en tales trabajos se preparó la figura 2. En ella se puede

notar algunos de los términos clave que caracterizan los artículos seleccionados. De esta selección, se pudo observar además que hay varios trabajos que no priorizan la limpieza de datos y no usan los algoritmos de clasificación que muestran mejores resultados. Como es de esperar, esto podría derivar en la obtención de resultados no óptimos o no confiables.

Como se mencionó anteriormente, la revisión consideró tres etapas que son parte de la minería de texto. En cuanto a la primera, una manera de recopilar la mayor cantidad de datos de los usuarios es usando las redes sociales. Hasta aquí puede notarse que la mayoría de los autores prefieren Twitter sobre el resto de las redes sociales para obtener datos ya que la información de esta red social en su mayoría es pública. Aunque en la actualidad existen muchas redes sociales en las que los usuarios publican y comentan sobre sus sentimientos, en los artículos existentes se reporta básicamente el trabajo con una red social o, en el mejor de los casos, con dos redes sociales, cada una para obtener datos. Una manera de lograr detectar a usuarios que puedan tener ansiedad de manera eficaz sería aplicar los métodos de recolección de datos a más de dos redes sociales en conjunto. Ya que generalmente los usuarios de cada red social utilizan unas más que otras, por ejemplo, los jóvenes suelen emplear más Twitter para expresar sus sentimientos y los mayores utilizan más Facebook. Por lo tanto, al recopilar datos de varias redes sociales en conjunto se puede determinar de manera más general los usuarios que padecen ansiedad, aunque esto requiera de más tiempo de procesamiento. Una vez que se obtiene un conjunto de datos, la limpieza de datos es necesaria para reducir el ruido en los datos de entrenamiento y hacer que los métodos de aprendizaje

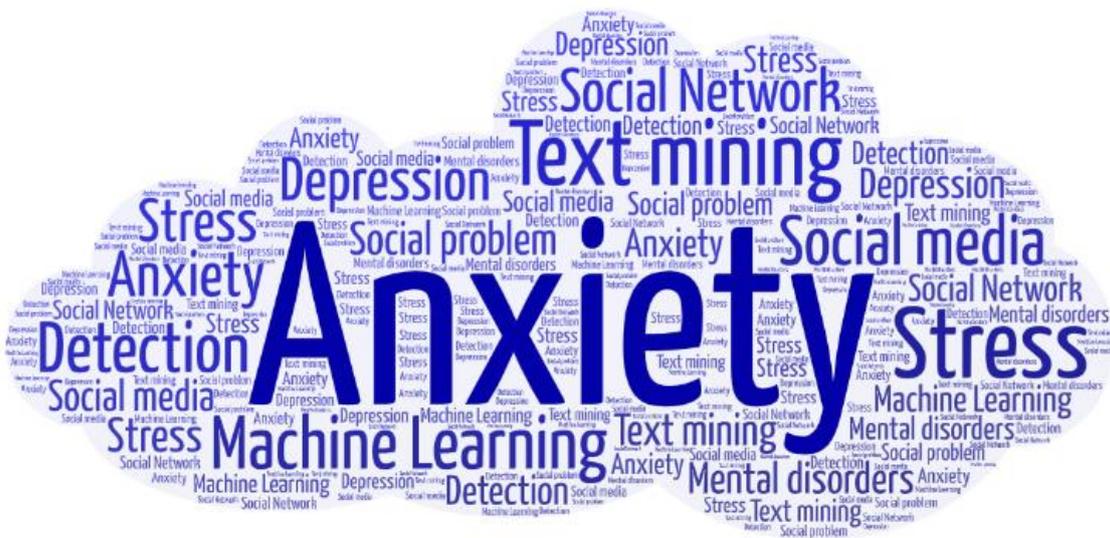


Figura 3. Nube de palabras referente a los artículos revisados

automático no “aprendan características erróneas”. Para esta técnica existen varios métodos como lo son el *stemming*, la *lemmatization*, y herramientas como NLTK y LIWC. Se recomienda en esta fase usar la *lemmatization* ya que esta permite relacionar una palabra derivada ya sea con su forma canónica o lema.

Por otro lado, para poder detectar a los usuarios que tienen el trastorno de ansiedad se usa la clasificación de datos que permite determinar la intención de los textos redactados por los usuarios. Esta técnica permite la identificación de los usuarios que puedan tener trastorno de ansiedad extrayendo estos datos de sus publicaciones. A pesar de que los trastornos de ansiedad son muy comunes en la actualidad, hay pocos intentos de creación de modelos basados en algoritmos como *random forest*, *XGBoost*, *CatBoost* y regresión logística que sean capaces de detectar automáticamente el trastorno. Para que este trastorno sea detectado de manera efectiva, adicionalmente se sugiere incluir conjuntos de datos más amplios con diagnósticos, evaluaciones o historiales médicos, con el fin de reforzar su validez.

Por último, al realizar este tipo de trabajos en los que se utiliza datos de usuarios es necesario tomar en cuenta que muchos de ellos son privados, por lo que lo ideal sería que el usuario otorgue el permiso para utilizar sus datos. Sin embargo, hay redes sociales como Twitter en la que la mayor parte de los datos de los usuarios son públicos y Weibo que también cuenta con datos de algunos usuarios que son públicos. Es primordial asegurarse de cuáles son las redes sociales que permiten el acceso a los datos de los usuarios de manera pública para no caer en invasión o violación de la privacidad de los usuarios

Conclusiones

En este trabajo se han revisado varios artículos que tratan sobre el uso de la minería de texto enfocada a la detección de ansiedad a partir de las publicaciones que realizan usuarios de redes sociales. Tal revisión permite concluir sobre la importancia de las tres fases aquí desarrolladas. En primer lugar, la recolección de datos se realiza fundamentalmente a partir de los datos de distintas redes sociales como Twitter, Facebook, Weibo y Reddit. Adicionalmente, algunos autores también han optado por obtener su conjunto de datos a partir de blogs o cuestionarios llenados por los usuarios participantes de los estudios. Aunque esto permitió que obtuvieran buenos resultados, se recomienda tomar datos de la mayor cantidad de redes sociales en conjunto ya que esto contribuirá a la obtención de resultados más generales de todo tipo de usuarios.

En segundo lugar, después de disponer de un conjunto de datos de redes sociales, es primordial procesar los datos apropiadamente. En esta etapa se limpian los datos para

que de esta manera no haya palabras vacías. Para el efecto, se usan herramientas o técnicas para que las palabras no se repitan o afecten el resultado, reconociendo si son derivadas de otras, o si son palabras vacías para tener datos precisos.

Por último, para realizar la detección de ansiedad, a los datos procesados se les aplica un algoritmo de aprendizaje. Los algoritmos más utilizados en este tipo de labor son *naive bayes*, regresión logística y SVM. En la mayoría de los casos, los algoritmos que obtuvieron la mayor precisión de optimización fueron la regresión logística y *random forest*, por lo cual se los recomienda, o a su vez se sugiere la creación de un modelo con mayor precisión utilizando como base los algoritmos *naive bayes*, regresión logística y SVM.

A pesar de los importantes avances en cuanto a detección de ansiedad basada en redes sociales, aún existen desafíos futuros. Es muy probable que las redes sociales continúen evolucionando, trayendo consigo nuevas posibilidades afines a lo aquí abordado. Tampoco se debe dejar fuera la posibilidad de integrar o combinar varias fuentes de datos. Este es el caso de los datos biomédicos o los registros médicos que pueden ser útiles para mejorar la precisión y la eficacia de los modelos para detectar ansiedad. También, aunque las técnicas actuales son útiles para tal detección, el disponer de otras más efectivas puede contribuir a la identificación de aquellos casos que requieran atención profesional urgente. En el global, se puede enfatizar en la importancia de continuar investigando en procura de mejorar la detección temprana de la ansiedad a partir de redes sociales con miras a apoyar a quienes la padecen.

Referencias

- [1] Moitra M. et al. The global gap in treatment coverage for major depressive disorder in 84 countries from 2000–2019: A systematic review and Bayesian meta-regression analysis. *PLoS Med.* 2022; 19(2), doi: 10.1371/JOURNAL.PMED.1003901.
- [2] Muhammad A. et al., “Classification of Anxiety Disorders using Machine Learning Methods: A Literature Review,” *Insights Biomed Res.* 2020; 4(1). doi: 10.36959/584/455.
- [3] Chang M. Y. and Tseng C. Y. Detecting Social Anxiety with Online Social Network Data. In *Proceedings - IEEE International Conference on Mobile Data Management.* 2020; vol. 2020-June: 333–336. doi: 10.1109/MDM48529.2020.00073.
- [4] O’Day E. B. and Heimberg R. G. Social media use, social anxiety, and loneliness: A systematic review. *Computers in Human Behavior Reports.* 2021; 3. doi: 10.1016/j.chbr.2021.100070.
- [5] Romano M., Moscovitch D. A., Ma R., and Huppert J. D. Social problem solving in social anxiety disorder. *J Anxiety Disord.* 2019; 68. doi: 10.1016/j.janxdis.2019.102152.
- [6] Budiyo S., Sihombing H. C., and Fajar Rahayu I. M. Depression and anxiety detection through the Closed-Loop method using DASS-21. *Telkonnika (Telecommunication Computing Electronics and Control).* 2019; 17(4). doi: 10.12928/TELKOMNIKA.v17i4.12619.

- [7] Sapountzi A. and Psannis K. E. Social Networking Data Analysis Tools & Challenges. *Future Generation Computer Systems*. 2016; 86: 893-913. doi: 10.1016/j.future.2016.10.019.
- [8] Tandel S. S., Jamadar A., and Dudugu S. A Survey on Text Mining Techniques. In *2019 5th International Conference on Advanced Computing & Communication Systems (ICACCS)*. 2019: 1022–1026. doi: 10.1109/ICACCS.2019.8728547.
- [9] Muhammad A. et al. Classification of Anxiety Disorders using Machine Learning Methods: A Literature Review. *Insights Biomed Res.* 2020; 4(1). doi: 10.36959/584/455.
- [10] Chang M. Y. and Tseng C. Y. Detecting Social Anxiety with Online Social Network Data. In *Proceedings - IEEE International Conference on Mobile Data Management*. 2020: 333–336. doi: 10.1109/MDM48529.2020.00073.
- [11] Avila D., Altamirano A., Avila J., and Guerrero G. Anxiety detection using the AMAS-C test and feeling analysis on the Facebook social network. In *2020 15th Iberian Conference on Information Systems and Technologies (CISTI)*. 2020. doi: 10.23919/CISTI49556.2020.9141104.
- [12] Gupta P. and Kaushik B. Suicidal Tendency on Social Media: A Case Study. In *2019 International Conference on Machine Learning, Big Data, Cloud and Parallel Computing (COMITCon)*. 2019. doi: 10.1109/COMITCon.2019.8862236.
- [13] Zhao Y. et al. Assessing Mental Health Signals among Sexual and Gender Minorities using Twitter Data. In *Proceedings - 2018 IEEE International Conference on Healthcare Informatics Workshops, ICHI-W*. 2018: 51–52. doi: 10.1109/ICHI-W.2018.00015.
- [14] Wang Y., Zhao Y., Bian J., and Zhang R. Detecting Signals of Associations between Dietary Supplement Use and Mental Disorders from Twitter. In *Proceedings - 2018 IEEE International Conference on Healthcare Informatics Workshops, ICHI-W*. 2018: 53–54. doi: 10.1109/ICHI-W.2018.00016.
- [15] Larsen M. E., Boonstra T. W., Batterham P. J., O’Dea B., Paris C., and Christensen H. We Feel: Mapping Emotion on Twitter. *IEEE J Biomed Health Inform.* 2015; 19(4): 1246–1252. doi: 10.1109/JBHI.2015.2403839.
- [16] Gruda D. and Hasan S. Feeling Anxious? Perceiving Anxiety in Tweets using Machine Learning. *Computers in Human Behavior*. 2019; 98: 245–255. doi: 10.1016/j.chb.2019.04.020.
- [17] Tariq S. et al. A Novel Co-Training-Based Approach for the Classification of Mental Illnesses Using Social Media Posts. *IEEE Access*. 2019; 7: 166165–166172. doi: 10.1109/ACCESS.2019.2953087.
- [18] Ta N., Li K., Yang Y., Jiao F., Tang Z., and Li G. Evaluating Public Anxiety for Topic-Based Communities in Social Networks. *IEEE Trans Knowl Data Eng.* 2022; 34(3): 1191–1205, Mar. 2022, doi: 10.1109/TKDE.2020.2989759.
- [19] Chen Y., Zhou H., Zhou Y., and Zhou F. Prevalence of self-reported depression and anxiety among pediatric medical staff members during the COVID-19 outbreak in Guiyang, China. *Psychiatry Res.* 2020; 288: 113005. doi: 10.1016/j.JPSYCHRES.2020.113005.
- [20] Alasadi S.A. and Bhaya W. S. Review of Data Preprocessing Techniques in Data Mining. *Journal of Engineering and Applied Sciences*. 2017; 12(16): 4102-4107.
- [21] Pradana A. W. and Hayaty M. The Effect of Stemming and Removal of Stopwords on the Accuracy of Sentiment Analysis on Indonesian-language Texts. *Kinetik: Game Technology, Information System, Computer Network, Computing, Electronics, and Control*. 2019; 4(4): 375–380. doi: 10.22219/kinetik.v4i4.912.
- [22] Akhmetov I. et al. Highly Language-Independent Word Lemmatization Using a Machine-Learning Classifier. *Computación y Sistemas*. 2020; 24(3): 1353–1364, 2020. doi: 10.13053/CYS-24-3-3775.
- [23] Yogish D., Manjunath T. N., and Hegadi R. S. Review on Natural Language Processing Trends and Techniques Using NLTK. In *Communications in Computer and Information Science*. 2019; 1037: 589–606. doi: 10.1007/978-981-13-9187-3_53.
- [24] Tadesse M. M., Lin H., Xu B., and Yang L. Detection of depression-related posts in reddit social media forum. *IEEE Access*. 2019; 7: 44883–44893, 2019, doi: 10.1109/ACCESS.2019.2909180.
- [25] Meshram S., Babu R., and Adhikari J. Detecting Psychological Stress using Machine Learning over Social Media Interaction. In *International Conference on Communication and Electronics Systems (ICCES)*. 2020. doi: 10.1109/ICCES48766.2020.9137931.
- [26] Yang J. and Zhang Y. NCRF++: An Open-source Neural Sequence Labeling Toolkit. *ACL 2018 - 56th Annual Meeting of the Association for Computational Linguistics, Proceedings of System Demonstrations*. 2018: 74–79. doi: 10.48550/arxiv.1806.05626.
- [27] Tyshchenko Y. Depression and anxiety detection from blog posts data. University of Tartu, Institute of Computer Science Computer Science Curriculum, Tesis de Maestría. 2018.
- [28] Ma L., Wang Z., and Zhang Y. Extracting depression symptoms from social networks and web blogs via text mining. In *Lecture Notes in Computer Science*. 2017; 10330: 325–330. doi: 10.1007/978-3-319-59575-7_29.
- [29] Islam M. R., Kabir M. A., Ahmed A., Kamal A. R. M., Wang H., and Ulhaq A. Depression detection from social network data using machine learning techniques. *Health Inf Sci Syst.* 2018; 6(1). doi: 10.1007/s13755-018-0046-0.
- [30] Kadhim A. I. Survey on supervised machine learning techniques for automatic text classification. *Artif Intell Rev.* 2019; 52(1): 273–292. doi: 10.1007/s10462-018-09677-1.
- [31] Thangaraj M. and Sivakami M. Text classification techniques: A literature review. *Interdisciplinary Journal of Information, Knowledge, and Management*. 2018; 13: 117–135, 2018, doi: 10.28945/4066.
- [32] Shen J. H. and Rudzicz F. Detecting anxiety on Reddit. In *IEEE Students Conference on Engineering and Systems (SCES)*. 2019: 58–65. doi: 10.18653/v1/W17-3107.
- [33] Hao J. and Ho T. K. *Machine Learning Made Easy: A Review of Scikit-learn Package in Python Programming Language*. Journal of Educational and Behavioral Statistics. SAGE Publications Inc. 2019; 44(3): 348–361. doi: 10.3102/1076998619832248.
- [34] Swati J., Narayan Suraj P., Rupesh K. D., Utkarsh B., Nalini M., and Varun K. A Machine Learning based Depression Analysis and Suicidal Ideation Detection System using Questionnaires and Twitter. In *IEEE Students Conference on Engineering and Systems (SCES)*. 2019. doi: 10.1109/SCES46477.2019.8977211.
- [35] Chen J., Zhao F., Sun Y., and Yin Y. Improved XGBoost model based on genetic algorithm. *International Journal of Computer Applications in Technology*. 2020; 62(3): 240–245, 2020, doi: 10.1504/IJCAT.2020.106571.
- [36] Palattao C. A. v., Solano G. A., Tee C. A., and Tee M. L. Determining factors contributing to the psychological impact of the COVID-19 Pandemic using machine learning. In *3rd International Conference on Artificial Intelligence in Information and Communication, ICAIIC*. 2021: 219–224. doi: 10.1109/ICAIC51459.2021.9415276.
- [37] Chadha A. and Kaushik B. A Survey on Prediction of Suicidal Ideation Using Machine and Ensemble Learning. *Computer Journal*. 2021; 64(11): 1617–1632. doi: 10.1093/comjnl/bxz120.
- [38] Priya A., Garg S., and Tigga N. P. Predicting Anxiety, Depression and Stress in Modern Life using Machine Learning Algorithms. In *Procedia Computer Science*. 2020; 167: 1258–1267. doi: 10.1016/j.procs.2020.03.442.
- [39] Sau A. and Bhakta I. Predicting anxiety and depression in elderly patients using machine learning technology. *Health Technol Lett.* 2017; 4(6): 238–243, 2017, doi: 10.1049/hlt.2016.0096.

- [40] Sau A. and Bhakta I. Screening of anxiety and depression among the seafarers using machine learning technology. *Inform Med Unlocked*. 2018; 16. doi: 10.1016/j.imu.2018.12.004.
- [41] Kumar P., Garg S., and Garg A. Assessment of Anxiety, Depression and Stress using Machine Learning Models. In *Procedia Computer Science*. 2020; 171: 1989–1998. doi: 10.1016/j.procs.2020.04.213.