

# Análisis comparativo de herramientas y APIs para la identificación y detección de depresión

Alexis Eduardo Colombo-Mendoza  
Tecnológico Nacional de México/I.T.  
Orizaba  
Orizaba, México  
[colombo101095@gmail.com](mailto:colombo101095@gmail.com)

Giner Alor-Hernández  
Tecnológico Nacional de México/I.T.  
Orizaba  
Orizaba, México  
[galorh@orizaba.tecnm.mx](mailto:galorh@orizaba.tecnm.mx)

María del Pilar Salas-Zarate  
Tecnológico Nacional de México/I.T.S.  
Teziutlán  
Teziutlán, México  
[maria.sz@teziutlan.tecnm.mx](mailto:maria.sz@teziutlan.tecnm.mx)

José Luis Sánchez-Cervantes  
CONACYT-Tecnológico Nacional de  
México/I.T. Orizaba  
Orizaba, México  
[jsanchezc@orizaba.tecnm.mx](mailto:jsanchezc@orizaba.tecnm.mx)

Lisbeth Rodríguez-Mazahua  
Tecnológico Nacional de México/I.T.  
Orizaba  
Orizaba, México  
[lrodriguez@orizaba.tecnm.mx](mailto:lrodriguez@orizaba.tecnm.mx)

**Resumen**— Los trastornos mentales como la depresión son un problema que afecta a una gran cantidad de personas en el mundo, muchas personas no buscan ayuda profesional, lo que les provoca tener una baja calidad de vida y en el peor de los casos los orilla a cometer suicidio. En este trabajo se presenta un análisis comparativo de un conjunto de herramientas y APIs existentes, que se especializan en la detección de entidades, emociones y sentimientos, para identificar y detectar depresión en textos en español. Se identificaron y se analizaron 5 APIs donde se realizó un benchmarking para identificar características de depresión en una nota suicida en un texto en español. Los principales hallazgos permiten establecer que MeaningCloud® ofrece mejores resultados en el proceso de identificación de emociones, mientras que ParalleDots® lo hace en el proceso de análisis de sentimientos

**Palabras clave**— Análisis Comparativo; Análisis de Sentimientos; Detección de Emociones; Inteligencia Artificial.

## I. INTRODUCCION

De acuerdo con la oficina de Información Científica y Tecnológica para el Congreso de la Unión, alrededor de 450 millones de personas en el mundo sufren de algún trastorno mental, y en México el 18% de la población de entre 15 y 64 años lo padece. Dichos trastornos son altamente estigmatizados, lo que contribuye significativamente al sufrimiento de las personas afectadas, provocando que eviten la búsqueda de ayuda profesional. Esto da como resultado una población motivada a ocultar o disfrazar sus síntomas. En los últimos años, el uso de redes sociales como canal para hablar sobre enfermedades o trastornos mentales se ha vuelto común, dando pie al uso de la información generada en ellas a fin de detectar dichos trastornos.

Se ha demostrado que las técnicas de Procesamiento del Lenguaje Natural (PLN) y aprendizaje automático se pueden emplear para hacer inferencias sobre el estado mental de las personas a partir del análisis de textos en distintos idiomas, de los cuales predomina el idioma inglés en las investigaciones existentes en la literatura, por lo que es necesario extender este tipo de investigación a otros idiomas, en este caso el español.

Por tal razón, en este trabajo se presenta un análisis comparativo de las APIs y herramientas existentes para el análisis de textos con el objetivo de identificar y detectar depresión. La contribución de este trabajo es el análisis y la realización de un benchmarking de las diferentes APIs y herramientas, mostrando características y resultados de cada una de ellas.

Este artículo está estructurado de la siguiente manera: la sección II presenta el estado del arte de la identificación de trastornos o enfermedades en textos, y la clasificación de textos en el dominio de la salud en general; la sección III presenta una descripción de las diferentes APIs analizadas, así como sus principales características; la sección IV habla del caso de estudio realizado; por último, en la sección V se cierra el artículo con una serie de conclusiones generales.

## II. ESTADO DEL ARTE

Existen diversas investigaciones en las que se abordan distintas técnicas, métodos o características para la identificación de trastornos mentales en textos, algunos métodos utilizan publicaciones de usuarios en redes sociales, mientras que otros hacen uso de otras técnicas, que tienen una relación con el tema propuesto.

Havigerova et al. [1] buscaron contribuir a la detección temprana de depresión en individuos, basado en el análisis de como las personas utilizan el idioma en combinación con sus características psicológicas. El objetivo del estudio fue encontrar modelos que predicen la depresividad del escritor a partir de los marcadores lingüísticos computacionales de su texto escrito. La depresión se midió mediante la escala de depresión, ansiedad y estrés (DASS-21). Como resultado se obtuvo que, en todos los participantes, los datos se ajustan mejor a los modelos predictivos de depresividad utilizando características morfológicas de texto informal.

En [2] los autores establecieron que la detección de depresión por medio de cuestionarios en línea es un proceso pasivo, ya que depende de que el individuo participe activamente en el proceso de detección. Por esta razón, buscaron analizar textos escritos por personas, como las publicaciones de sus blogs personales, e identificar signos de depresión en el texto mediante un análisis automático. Para la detección de depresión por medio de análisis de textos, presentaron un sistema que se basa en un enfoque para identificar el significado asociado con un término objetivo a través del análisis metafórico. Por último, presentaron tres casos de prueba, en los que se demostró que el sistema puede funcionar como auxiliar para un experto de la salud mental para realizar la detección de depresión.

Con el rápido crecimiento y auge del Internet, surgen nuevas necesidades de construir sistemas inteligentes, que sean capaces de tratar de manera eficiente los problemas de detección temprana de riesgos en las redes sociales, como la detección temprana de depresión, la detección temprana de

rumores, entre otros. Con base en esta premisa en [3] los autores propusieron un modelo de aprendizaje supervisado para la clasificación de textos que ayuda en las tareas de detección temprana de riesgos, llamado SS3. Los resultados experimentales muestran que el clasificador propuesto fue capaz de superar modelos y clasificadores estándar como *Support Vector Machine* o redes neuronales, entre otros.

En [4] los autores establecieron que pocos estudios se interesaron en evaluar y mejorar los recursos léxicos para apoyar a la detección de signos de depresión en el texto. Por lo tanto, presentaron una metodología basada en búsquedas para evaluar la léxica de depresión existente. Para lograr lo anterior, utilizaron los recursos existentes para la depresión y el uso del lenguaje y analizaron qué elementos del léxico son los más efectivos para revelar los síntomas de la depresión. Los experimentos realizados mostraron que la léxica resultante es eficaz para identificar signos de depresión y se puede utilizar para analizar texto de forma no supervisada. Al identificar los componentes más importantes de la léxica original y expandirlos con términos relacionados, obtuvieron una imagen más completa de los artefactos lingüísticos que las personas usan para expresar la depresión.

Un desafío importante para la detección automática de emociones, es que estas son conceptos subjetivos con límites difusos y con variaciones en la expresión y la percepción. Para abordar este problema, en [5] se propuso un modelo dimensional de afecto para definir las clases de emociones. Además, se propuso un enfoque de clasificación suave para medir la probabilidad de asignar un mensaje a cada clase de emoción. Por último, se desarrolló y evaluó un sistema de aprendizaje supervisado para clasificar automáticamente las emociones en los mensajes de texto. Los experimentos realizados muestran que los modelos creados clasifican correctamente las emociones en el 90% de los mensajes de texto.

Stasak et al. [6] establecieron que, en el futuro, el análisis automático de la salud mental basado en el habla podría estar ampliamente disponible para ayudar a mejorar los métodos convencionales de evaluación de la salud. Además, propusieron una investigación de los comportamientos de difluencia del habla en hablantes no deprimidos / deprimidos utilizando texto leído en voz alta que contiene criterios afectivo-lingüísticos restringidos. El análisis demostró diferencias de características estadísticamente significativas en las difluencias del habla, por lo que, en comparación con los hablantes no deprimidos, los hablantes deprimidos mostraron frecuencias registradas relativamente más altas de vacilaciones (aumento del 55%) y errores del habla (Aumento del 71%).

En [7] los autores propusieron un modelo supervisado para detectar automáticamente usuarios depresivos en las redes sociales, con un enfoque que se basa en grupos de características que van desde una bolsa estándar de palabras y características superficiales hasta características con más información lingüística. El enfoque presentado se evaluó en publicaciones de Reddit, en los dos siguientes casos: a) dadas las publicaciones de un usuario, detectar si el usuario correspondiente es depresivo o no, b) dado un historial de escritos del usuario, detectar temprano signos de depresión. Los resultados mostraron que el enfoque es confiable para ambas tareas.

Birnbaum et al. [8] establecieron que, los modelos computacionales basados en el lenguaje, que buscan la identificación de los individuos que padecen esquizofrenia sin un diagnóstico médico confirmado, mediante el escaneo de *feeds* de Twitter lograron más del 80% y 90% de precisión en la identificación correcta de usuarios con esquizofrenia auto informada. Sin embargo, el problema de dichos modelos es confirmar la autenticidad de las revelaciones en línea, además, las investigaciones previas demostraron que las palabras detectadas como “psicosis”, o, “esquizofrenia”, a menudo se usan en línea de manera inapropiada y representan una limitación para los modelos mencionados. En busca de obtener identificaciones precisas, se propuso un enfoque humano-máquina asociado, en el que el análisis lingüístico del contenido compartido en las redes sociales se combine con evaluaciones clínicas, para determinar así la utilidad de las redes sociales como una herramienta de diagnóstico viable para identificar a las personas con esquizofrenia.

Min Yen-Wu et al. propusieron en [9] un enfoque automático de detección de depresión, denominado detección de depresión basada en aprendizaje profundo con fuentes de datos heterogéneas (D3-HDS), para predecir la etiqueta de depresión de un individuo mediante el análisis de su entorno de vida, comportamiento y el contenido publicado en las redes sociales. El método propuesto emplea redes neuronales recurrentes para calcular la representación de mensajes de cada individuo. Las representaciones se combinan con otras características para predecir la etiqueta de depresión del individuo con Redes Neuronales Profundas. Después de la realización de pruebas con el método propuesto, se concluyó que, este enfoque supera a otras líneas de base, y brinda resultados satisfactorios en las tareas de clasificación de personas que padecen depresión.

En [10] se mencionó que, aproximadamente un millón de personas sufren depresión en Taiwán y uno de cada cuatro estudiantes en ese país sufre este trastorno y requieren asistencia profesional. Los autores sostuvieron que, la depresión está expresada en los lenguajes nativos de los usuarios, por lo que propusieron un modelo de tendencia depresiva basado en palabras clave para detectar indicios de depresión en artículos chinos publicados en una importante plataforma de redes sociales en Taiwán, PTT, que es un medio de comunicación social culturalmente específico. La tendencia hacia la depresión se definió basándose en DSM-5 (*Diagnostic and Statistical Manual of Mental Disorders*, Manual Diagnóstico y Estadístico de los Trastornos Mentales), que es un clasificador estándar de trastornos mentales utilizado en Estados Unidos. Como conclusión, se cumplió el objetivo principal del estudio, que fue establecer un léxico de depresión utilizando técnicas de análisis de datos, dicho léxico da apoyo a la toma de decisiones al poder detectar indicios de depresión en las publicaciones en las redes sociales.

J. Wolohan et al. propusieron en [11] un enfoque de aprendizaje automático basado en características lingüísticas para detectar la depresión en los usuarios de Reddit cuando no estén hablando explícitamente de depresión, como sería el caso de las personas sensibles al estigma público de dicho trastorno. Los autores mencionan que, los modelos realizados hasta el momento en las investigaciones existentes podrían estar sobre-ajustados a las señales relacionadas con la depresión, y, que dichos modelos tendrán un rendimiento inferior para usuarios que no hacen mención manifiesta de este

trastorno en sus publicaciones. Como resultado de la investigación, se concluyó que las tareas de clasificación se tornan más difíciles en el conjunto de datos que no menciona explícitamente los trastornos depresivos, sin embargo, los clasificadores de aprendizaje automático aún pueden detectar rastros lingüísticos de depresión.

Tadesse et al. propusieron en [12] un enfoque que busca mostrar el poder predictivo de las características simples y combinadas con enfoques de clasificación propuestos para lograr un mayor rendimiento en las tareas de identificación de la depresión. Como resultado de la investigación, se identificó un léxico de palabras más común entre las cuentas de los usuarios deprimidos. Además, después de examinar el rendimiento de las combinaciones se obtuvo como máxima efectividad de las características combinadas un 91% de precisión y una puntuación F1 de 0.93 con el clasificador MLP (*Multilayer Perceptron, Perceptron Multicapa*), que es el mayor grado de rendimiento para detectar la presencia de depresión en la red social Reddit.

En [13] se realizó una investigación que tuvo como objetivo explorar el uso del aprendizaje automático para una detección temprana de depresión utilizando WFs (*Writing Features, Características de Escritura*), de contenido de redes sociales, para mejorar los métodos de vanguardia existentes hasta el momento del estudio. Los autores propusieron dos enfoques para la detección de la depresión en una etapa temprana, utilizando datos de redes sociales. Ambos enfoques están basados en el aprendizaje automático, y fueron llamados Singleton y Dual. El primero utiliza un clasificador *Random Forest*, con dos funciones de umbral, mientras que el segundo, utiliza dos clasificadores independientes. Los resultados de la investigación arrojaron que, el enfoque dual obtuvo un mejor rendimiento, incluso en comparación con los modelos de detección más modernos al momento del estudio, mejorando su efectividad hasta en un 10%.

Trotzek et al. señalaron en [14] que las tareas de identificación de trastornos mentales, como la depresión, representan aún un reto de gran tamaño para el dominio médico y tecnológico, y para la sociedad en general, ya que, la vergüenza y autoestigmatización de dichos trastornos son razones fuertes en los afectados para no buscar ayuda psiquiátrica. Los autores propusieron una red neuronal convolucional basada en diferentes incorporaciones de palabras y se comparó con una clasificación basada en metadatos lingüísticos a nivel de usuario, en busca de la detección de depresión en una etapa temprana, a través de una plataforma social. Tras las pruebas realizadas, se demostró que el conjunto del enfoque logró resultados de vanguardia en la tarea de detección temprana.

Tras haber analizado minuciosamente los trabajos mencionados anteriormente, se concluye que la utilización de redes sociales para detección de trastornos mentales se convirtió en un método con resultados aceptables. Es importante destacar que, la mayoría de los trabajos se centran en la identificación de la depresión, dejando de lado otros trastornos mentales importantes. Además, los investigadores se han enfocado en realizar las pruebas y experimentos de detección de depresión sobre conjuntos de datos establecidos por ellos mismos con anticipación, lo que puede dar lugar al sobreajuste de los modelos. La importancia de este trabajo, radica en la selección adecuada de herramientas y APIs para la detección de depresión en texto en el idioma español.

### III. IDENTIFICACIÓN DE LAS APIS PARA LA DETECCIÓN DE EMOCIONES, SENTIMIENTOS Y ENTIDADES

Existen distintas APIs y herramientas que por medio de técnicas de Procesamiento del Lenguaje Natural brindan servicios para el procesamiento de textos. El PLN es un campo de las ciencias de la computación, de la inteligencia artificial y de la lingüística que estudia las interacciones entre las computadoras y el lenguaje humano.

Las principales capacidades que se buscan en las APIs en esta investigación, para poder realizar la detección de la depresión, son la detección de entidades, el análisis de sentimientos y la detección de emociones.

La detección de entidades se entiende como el proceso de identificar automáticamente dentro de un texto, las entidades que se nombran, entendiendo como entidad algo concreto, físicamente delimitado, que posee un nombre. El análisis de sentimientos trata de determinar la actitud del autor de un texto, con respecto a algún tema en específico o general, y busca obtener la polaridad contextual de dicho texto, teniendo como objetivo obtener una puntuación que indique si expresa una opinión positiva, negativa, o neutra, normalmente en una escala de valores que va de cero a uno. Finalmente, la detección de emociones, busca identificar dentro de un texto, las emociones que el autor trata de plasmar en él y se le asigna un valor dentro de la escala del cero a uno, para identificar la emoción con mayor o menor presencia dentro del texto. A continuación, se presenta una breve descripción de cada API o herramienta que se analizó en esta sección del trabajo.

ParallelDots AI API® [15] es un conjunto de APIs de Inteligencia Artificial, que tiene capacidades para la clasificación de documentos y el Procesamiento del Lenguaje Natural, enfocado a los desarrolladores de software.

IBM Watson API® [16] es un conjunto de APIs de voz, texto, video, entre otras. La API de IBM para análisis de textos permite analizar sentimientos, emociones, palabras claves, entidades, categorías, conceptos, y sintaxis del texto.

TheySay Preceive API® [17] es un servicio independiente de la plataforma que permite a los desarrolladores acceder y combinar procesadores de análisis de texto que cubren el análisis de sentimientos, la detección de especulaciones, el etiquetado de parte del discurso, el análisis de dependencias y otros.

FreeLing® [18] es una biblioteca que proporciona funcionalidades de análisis de idiomas (análisis morfológico, detección de entidades con nombre, etiquetado de PoS, análisis, desambiguación de Word Sense, etiquetado de roles semánticos, etc.) para una variedad de idiomas.

DeepAffects API® [19] reúne capacidades de análisis y reconocimiento de audio, texto y video. Dentro de la API de reconocimiento de texto se encuentra disponible el resumen conversacional, reconocimiento de emociones, puntuación inteligente, entre otros.

MeaningCloud API® [20] es una plataforma que ofrece distintos servicios y productos, entre los que destacan las APIs de análisis de sentimientos, categorización profunda, clasificación de textos, extracción de tópicos, entre otros.

En la tabla 1 se muestra la comparativa de las capacidades entre las APIs mencionadas.

**Tabla 1. Comparativa de las APIs para la detección de emociones, entidades y análisis de sentimiento**

API / herramienta	Detección de entidades	Análisis de sentimientos	Detección de emociones
ParallelDots AI API®	Sí Nombres (personas), grupos, lugares	Sí Negativo, neutro, positivo	Sí (inglés) Enojo, felicidad, aburrimiento, miedo, tristeza, emoción
IBM Watson API®	Sí Compañías, ubicaciones, organizaciones, personas, cantidades	Sí Negativo, neutro, positivo	Sí (inglés) Alegría, ira, disgusto, tristeza, miedo
TheySay Preceive API®	Sí Personas, horas y fechas, ubicación, dinero	Sí Negativo, neutro, positivo	Sí Enfado, miedo, felicidad, gusto, vergüenza, duda, sorpresa, calma, certeza
FreeLing®	Sí Personas, ubicaciones, organizaciones, otros	No	No
DeepAffects API®	No	No	Sí Sorpresa, alegría, confianza, tristeza, miedo, enojo, disgusto
MeaningCloud API®	Sí Personas, lugares, organizaciones, otros	Sí (sin especificar cantidad) Positivo, negativo, neutro	Sí Tristeza, alegría, confianza, ira, aversión, anticipación

Como se observa en la tabla 1, las APIs de ParallelDots® e IBM Watson® proveen servicios para la detección de entidades, sentimientos y emociones, pero no cuentan con soporte en español para la detección de emociones. Asimismo, algunas de las APIs y herramientas analizadas solo cuentan con uno de los tres aspectos deseados, como FreeLing® y DeepAffects®, sin embargo, este no es un factor para descartarlas.

Es importante señalar que el API de MeaningCloud® cuenta con los tres aspectos que se buscan en este análisis, incluso con soporte para el idioma español, lo que la hace distinguirse como la más completa.

Cabe mencionar que el API de TheySay® se encuentra a la par que la API de MeaningCloud®, pero queda descartada por no contar con soporte para desarrolladores activo al momento de realizar esta investigación.

**IV. CASO DE ESTUDIO “IDENTIFICACIÓN DE DEPRESIÓN EN TEXTO EN UNA NOTA SUICIDA”**

Para probar la funcionalidad de las APIs seleccionadas anteriormente e identificar aspectos de depresión en textos, se decidió trabajar bajo un caso de prueba, el cual trata de un texto en idioma español con una extensión de aproximadamente 500 palabras, en el cual se utilizan términos y frases negativas, tratando de plasmar en él, un enfoque de una “carta suicida”. Un fragmento del texto se coloca a continuación, seguido de los resultados obtenidos al probar las APIs y se muestran las interfaces gráficas del módulo de pruebas desarrollado para llevarlas a cabo.

El siguiente fragmento de texto pertenece al caso de prueba que se utilizó:

*“Ya no sé qué hacer, estoy desesperada, ya no puedo, quiero gritar, ya no puedo más, ya estoy harta yo quiero acabar con todo, esta es una maldita ansiedad, como si necesitara algo, pero no sé qué es y me enoja y me da tristeza ya no saber qué hacer y pienso que no puedo más, siento como mi corazón late tan rápido de desesperación y no saber qué hacer me mata por dentro. No estoy sola tengo una gran familia que me apoya y me quiere, pero no es suficiente, y lo peor es no saber porque, ahora siento como me está costando respirar y todo por no saber qué está pasando conmigo en mi*

*cabeza, con mis pensamientos, con mi ser, ya no puedo más quiero gritar a los cuatro vientos que alguien acabe con esto y ponga fin a tanta infelicidad... Como siempre. Nadie tiene una maldita idea de qué es ver a los demás felices y no poder hacerlo, respirar y no sentirse viva, llorar hasta quedar dormida y sólo reír por momentos, recordar lo horrible y asquerosa que puede ser la vida, que todos hablen de un dios y no poder verlo o sentirlo, el amor no existe y que la gente es falsa y mentirosa. Saber que todo lo que haces es un error y jamás tendrás razón, quiere vivir un recuerdo, una novela, sólo poder tener un final feliz...”*

Con base en el análisis de la tabla 1, para la realización de este caso de estudio se utilizó para la detección de entidades, la combinación de las APIs de ParallelDots AI® y MeaningCloud®, ya que ambas tienen soporte para identificación de las entidades nombradas en idioma español, además de que son capaces de detectar en conjunto cinco grupos distintos de entidades. Para realizar el análisis de sentimientos se decidió utilizar nuevamente la API de ParallelDots AI®, ya que cuenta con soporte al idioma español, además de que arroja resultados con una escala de valores numéricos. Por último, la detección de emociones se realizó nuevamente con una combinación, en este caso, de las APIs de MeaningCloud® y DeepAffects®, ya que ambas cuentan con soporte al idioma español y en conjunto logran reunir hasta 10 emociones distintas. Es importante señalar que MeaningCloud® retorna una cantidad variada de emociones, en respuesta a lo que identifique en el texto, mientras que DeepAffects® regresa una sola emoción general, en conjunto con su valor asociado. En la tabla 2, se presentan los resultados obtenidos con el módulo de pruebas.

**Tabla 2. Resultados de las pruebas**

API	Análisis de sentimientos	Detección de emociones
ParallelDots AI API®	Negative: 0.772 Neutral: 0.024 Positive: 0.205	-
DeepAffects API®	-	Tristeza: 0.73
MeaningCloud API®	-	Tristeza: 1 Alegría: 0.89 Aversión: 0.56 Ira: 0.44 Confianza: 0.11

Con el objetivo de contrastar los resultados obtenidos en el caso de estudio, a continuación se presenta un fragmento del texto que se utilizó como una segunda prueba, esta vez tratando de dar un enfoque totalmente contrario al del caso de estudio de la nota suicida mostrada anteriormente. De igual forma, se trata de un texto con una extensión aproximada de 500 caracteres, en donde se utilizan frases y emociones positivas, buscando obtener de esta manera, resultados con emociones y polaridad positiva.

*“Espero estén ejerciendo a pleno su pasión por la vida y voluntad de mejorar día a día, pues esos son algunos de los ingredientes que necesitarán para crear la receta de la pasión. En mi experiencia, me doy una dosis de sonrisas diaria, por las mañanas es el comienzo, agradecer el haber amanecido y las cosas que tenemos y aquellas que no tenemos, ni tenemos que tener, seguido de eso, me propondría dos objetivos, uno para lograr el día y otro a más largo plazo. Siempre es reconfortante para nuestra autoestima darnos cuenta de que podemos lograr lo que nos proponamos y cierto es que, si nos enfocamos en algo, lo podemos realizar. Hay veces que la vida nos va mostrando que ciertas cosas no son para nosotros o que nos equivocamos de camino. Debemos estar atentos. Otro ingrediente de esta preciada pastilla que queremos fabricar, es lograr un equilibrio de sanidad mental, física y espiritual. Recordemos que mantener nuestra mente creativa y libre de pensamientos negativos, aunque pueda costarnos, nos regala un resultado muy placentero.”*

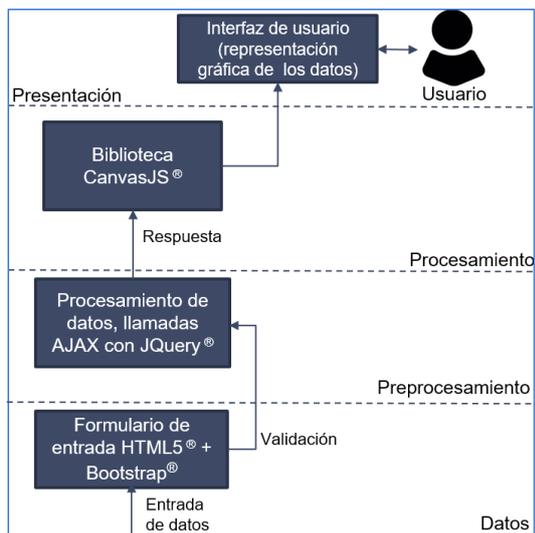
En la tabla 3, se presentan los resultados obtenidos con el módulo de pruebas y el texto de enfoque positivo.

**Tabla 3. Resultados con prueba de texto positivo.**

API		Análisis de sentimientos	Detección de emociones
ParallelDots AI API®		Negative: 0.017 Neutral: 0.023 <b>Positivo: 0.959</b>	-
DeepAffects API®		-	<b>Tristeza: 0.73</b>
MeaningCloud API®		-	<b>Alegría: 1</b> Confianza: 0.21

En la figura 1 se presenta el diseño de la arquitectura del módulo desarrollado.

**Figura 1. Diseño de la arquitectura del módulo**



Como se puede observar, el flujo comienza en la capa de datos, cuando el usuario ingresa los datos de entrada, los cuales se explicarán a continuación, al mostrar sus respectivas interfaces gráficas. Los datos de entrada son procesados y validados con JQuery® y enviados mediante método POST con AJAX a los endpoints de las APIs. La respuesta devuelta por las APIs se convierte al formato que espera recibir la biblioteca de CanvasJS® y se le envía. Ésta última convierte los datos a una representación gráfica, específicamente una gráfica de pastel para la representación del análisis de sentimientos y una gráfica de barras para la representación de la detección de emociones.

Por último, se presentan las interfaces gráficas del módulo desarrollado para realizar las pruebas, con una breve descripción de cada una de ellas, asimismo se muestran los resultados de manera gráfica.

Como se puede observar en la figura 2, la primera interfaz gráfica solicita al usuario ingresar los parámetros de entrada, los cuales son:

- API a utilizar (ParallelDots AI®, MeaningCloud®, DeepAffects®)
- Aspecto a detectar (entidades, emociones, sentimiento)
- Idioma (español e inglés)
- Texto a analizar

Como parámetro de salida se obtiene una respuesta distinta de las APIs dependiendo del aspecto a identificar, y se representan mediante gráficas, las cuales se muestran a continuación.

**Figura 2. Formulario módulo de pruebas**



La figura 3, presenta los resultados obtenidos tras realizar la detección de emociones con el API de MeaningCloud®, con el texto del caso de prueba de enfoque negativo, en el idioma español y los representa mediante una gráfica de barras.

**Figura 3. Resultados detección de emociones**



Por último, en la figura 4 se presenta de manera gráfica los resultados obtenidos tras realizar el análisis de sentimientos con la API de ParallelDots®, con el texto de caso de prueba de enfoque negativo en idioma español y los representa mediante una gráfica de pastel, en donde se observa que la mayor parte del texto se compone de un sentimiento negativo.

**Figura 4. Resultados análisis de sentimiento**



**V. CONCLUSIONES**

Las técnicas de Procesamiento de Lenguaje Natural, en específico, la detección de emociones y el análisis de sentimientos son un área de la cual es posible apoyarse para realizar inferencias para la detección de trastornos mentales como la depresión o la ansiedad, asociando las emociones de los textos a los distintos síntomas que pueden presentar las personas al sufrir de dichos trastornos.

Tras haber realizado un análisis minucioso de las distintas APIs de Procesamiento del Lenguaje Natural y haberlas puesto a prueba mediante un caso de estudio, se concluye que los mejores resultados en cuanto a la detección de entidades se obtuvieron con el API de MeaningCloud®, ya que clasifica a las entidades nombradas en cuatro grupos, en los cuales no tuvo errores en las entidades halladas para cada uno. Los resultados más acertados en el análisis de sentimiento los ofrece el API de ParallelDots®, ya que obtiene una polaridad negativa del texto con enfoque negativo bastante cercana al 0.8, dejando la polaridad positiva en un muy bajo valor, y obtuvo una polaridad neutra casi nula. En el caso de la

segunda prueba, con el texto de un enfoque positivo, obtuvo una polaridad positiva bastante cercana al 0.96, mientras que la polaridad neutra y negativa las obtuvo como un 0.02 y 0.01 respectivamente. Por último, en la detección de emociones el API más completa y con resultados más acertados fue MeaningCloud®, ya que, en sus resultados con el caso de prueba de enfoque negativo, predominan las emociones negativas como la tristeza, la aversión o la ira, ante las positivas como la alegría y la confianza, incluso la emoción de tristeza obtuvo el mayor valor numérico, llegando completamente al 1, mientras que el resto de emociones se clasificaron con números decimales menores al 1. En el caso de prueba con enfoque positivo obtuvo únicamente emociones positivas como la alegría y la confianza y ninguna emoción negativa. Por estas razones, se concluye que los resultados obtenidos son lo suficientemente acertados para poder utilizar estas técnicas como un auxiliar para la identificación y detección de depresión en textos en idioma español.

Como trabajo a futuro se pretende realizar la identificación y detección de depresión de forma automática, extrayendo información de usuarios directamente de medios sociales como Twitter® y Reddit®. Así también, se considera realizar un análisis más amplio incluyendo otras APIs tales como Semantria API®, Aylieon Text API®, Natural Language API®, entre otros. Finalmente, se pretende abordar otros idiomas para la detección de depresión, así como la identificación de otros trastornos mentales tales como la ansiedad y esquizofrenia.

**AGRADECIMIENTOS**

Este trabajo de investigación fue patrocinado por parte del Consejo Nacional de Ciencia y Tecnología (CONACyT).

**REFERENCIAS**

- [1] J. M. Havigerová, J. Haviger, D. Kučera, y P. Hoffmannová, "Text-Based Detection of the Risk of Depression", *Front. Psychol.*, vol. 10, 2019, doi: 10.3389/fpsyg.2019.00513.
- [2] Y. Neuman, Y. Cohen, D. Assaf, y G. Kedma, "Proactive screening for depression through metaphorical and automatic text analysis", *Artif. Intell. Med.*, vol. 56, núm. 1, pp. 19–25, sep. 2012, doi: 10.1016/j.artmed.2012.06.001.
- [3] S. G. Burdisso, M. Errecalde, y M. Montes-y-Gómez, "A text classification framework for simple and effective early depression detection over social media streams", *Expert Syst. Appl.*, vol. 133, pp. 182–197, nov. 2019, doi: 10.1016/j.eswa.2019.05.023.
- [4] D. E. Losada y P. Gamallo, "Evaluating and improving lexical resources for detecting signs of depression in text", *Lang. Resour. Eval.*, vol. 54, núm. 1, pp. 1–24, mar. 2020, doi: 10.1007/s10579-018-9423-1.
- [5] M. Hasan, E. Rundensteiner, y E. Agu, "Automatic emotion detection in text streams by analyzing Twitter data", *Int. J. Data Sci. Anal.*, vol. 7, núm. 1, pp. 35–51, feb. 2019, doi: 10.1007/s41060-018-0096-z.
- [6] B. Stasak, J. Epps, y R. Goecke, "Automatic depression classification based on affective read sentences: Opportunities for text-dependent analysis", *Speech Commun.*, vol. 115, pp. 1–14, dic. 2019, doi: 10.1016/j.specom.2019.10.003.
- [7] F. Benamara, V. Moriceau, J. Mothe, F. Ramiandrisoa, y Z. He, "Automatic Detection of Depressive Users in Social Media", Rennes, France, may 2018, doi: 10.24348/coria.2018.paper4.
- [8] M. L. Birnbaum, S. K. Ernala, A. F. Rizvi, M. D. Choudhury, y J. M. Kane, "A Collaborative Approach to Identifying Social Media Markers of Schizophrenia by Employing Machine

- Learning and Clinical Appraisals”, *J. Med. Internet Res.*, vol. 19, núm. 8, p. e289, 2017, doi: 10.2196/jmir.7956.
- [9] M. Y. Wu, C.-Y. Shen, E. T. Wang, y A. L. P. Chen, “A deep architecture for depression detection using posting, behavior, and living environment data”, *J. Intell. Inf. Syst.*, oct. 2018, doi: 10.1007/s10844-018-0533-4.
- [10] H.-W. Hu *et al.*, “Keyword-Driven Depressive Tendency Model for Social Media Posts”, en *Business Information Systems*, vol. 354, W. Abramowicz y R. Corchuelo, Eds. Cham: Springer International Publishing, 2019, pp. 14–22.
- [11] J. Wolohan, M. Hiraga, A. Mukherjee, Z. A. Sayyed, y M. Millard, “Detecting Linguistic Traces of Depression in Topic-Restricted Text: Attending to Self-Stigmatized Depression with NLP”, en *Proceedings of the First International Workshop on Language Cognition and Computational Models*, Santa Fe, New Mexico, USA, ago. 2018, pp. 11–21, Consultado: ene. 14, 2020. [En línea]. Disponible en: <https://www.aclweb.org/anthology/W18-4102>.
- [12] M. M. Tadesse, H. Lin, B. Xu, y L. Yang, “Detection of Depression-Related Posts in Reddit Social Media Forum”, *IEEE Access*, vol. 7, pp. 44883–44893, 2019, doi: 10.1109/ACCESS.2019.2909180.
- [13] F. Casheda, D. Fernandez, F. J. Novoa, y V. Cameiro, “Early Detection of Depression: Social Network Analysis and Random Forest Techniques”, *J. Med. Internet Res.*, vol. 21, núm. 6, p. e12554, 2019, doi: 10.2196/12554.
- [14] M. Trotzek, S. Koitka, y C. Friedrich, “Utilizing Neural Networks and Linguistic Metadata for Early Detection of Depression Indications in Text Sequences”, *IEEE Trans. Knowl. Data Eng.*, vol. PP, abr. 2018, doi: 10.1109/TKDE.2018.2885515.
- [15] “ParallelDots | World Class NLP APIs for Text Analysis”. <https://www.paralleldots.com/text-analysis-apis> (consultado sep. 24, 2020).
- [16] “IBM | Watson”. <https://cloud.ibm.com/developer/watson/documentation> (consultado oct. 22, 2020).
- [17] “TheySay PreCeive API Documentation · Apiary”. <https://theysay.docs.apiary.io/#> (consultado oct. 09, 2020).
- [18] “Welcome | FreeLing Home Page”. <http://nlp.lsi.upc.edu/freeling/node/1> (consultado sep. 24, 2020).
- [19] “DeepAffects - Speech Analysis Platform”, *DeepAffects*. <https://www.deepaffects.com/> (consultado oct. 22, 2020).
- [20] “APIs | MeaningCloud”. <https://www.meaningcloud.com/developer/apis> (consultado oct. 09, 2020).