

Eficacia de Modelos Predictivos de Machine Learning en el diagnóstico temprano de la depresión: una revisión sistemática

Effectiveness of Machine Learning Predictive Models in the Early Diagnosis of Depression: A Systematic Review

Daniel Junior López Angeles

<https://orcid.org/0009-0000-2308-0080>

daniel.lopez7@unmsm.edu.pe

Universidad Nacional Mayor de San Marcos, Lima, Perú

RECIBIDO: 06/12/2024 - ACEPTADO: 15/12/2024 - PUBLICADO: 31/12/2024

RESUMEN

El presente artículo de Revisión Sistemática busca contribuir con un estudio analítico comparativo de diferentes métodos de aprendizaje de máquina para detectar signos de depresión a partir de los algoritmos de Machine Learning (ML) donde convergen la inteligencia artificial y la salud mental. Este diseño no solo proporciona una visión integral de los avances científicos, sino que también identifica lagunas en la investigación que pueden orientar futuras iniciativas. Asimismo, el análisis de los hallazgos en el marco de un diseño sistemático garantiza la generación de recomendaciones basadas en evidencia para la implementación de herramientas predictivas en sistemas de salud pública, como el peruano. En cuanto a la carga socioeconómica de este trastorno, es necesario realizar una detección adecuada de la depresión con el objetivo de reducir los tiempos de diagnóstico y permitir identificar señales en interacciones sociales cotidianas. Asimismo a pesar de los avances prometedores, persisten desafíos relacionados con la generalización y la interpretabilidad de los modelos predictivos. La heterogeneidad de los síntomas depresivos y las diferencias demográficas entre poblaciones limitan la aplicabilidad universal de estos modelos (Nickson D. M., 2023). No obstante, la integración de machine learning en la práctica clínica representa una oportunidad significativa para mejorar la detección temprana y el tratamiento de la depresión, contribuyendo a una atención más personalizada y efectiva (Bhaumik, 2023).

En resumen, la implementación de modelos de aprendizaje automático en la salud mental muestra un avance prometedor en la predicción y diagnóstico de trastornos mentales. Sin embargo, persisten desafíos significativos relacionados con la calidad de los datos, los sesgos y la aplicabilidad clínica. La investigación continua y la mejora de estos modelos son esenciales para maximizar su precisión y utilidad en el tratamiento de problemas de salud mental, permitiendo intervenciones más tempranas y personalizadas.

Palabras claves: Salud Mental, Aprendizaje de Máquina, Depresión, Aprendizaje profundo, Trastornos mentales.

ABSTRACT

This Systematic Review article seeks to contribute with a comparative analytical study of different machine learning methods to detect signs of depression from Machine Learning (ML) algorithms where artificial intelligence and mental health converge. This design not only provides a comprehensive view of scientific advances, but also identifies gaps in research that can guide future initiatives. Likewise, the analysis of the findings within the framework of a systematic design guarantees the generation of evidence-based recommendations for the implementation of predictive tools in public health systems, such as the Peruvian one. Regarding the socioeconomic burden of this disorder, it is necessary to carry out adequate detection of depression in order to reduce diagnostic times and allow the identification of signs in daily social interactions. Likewise, despite promising advances, challenges related to the generalization and interpretability of predictive models persist. The heterogeneity of depressive symptoms and demographic differences between populations limit the universal applicability of these models (Nickson D. M., 2023). However, the integration of machine learning into clinical practice represents a significant opportunity to improve early detection and treatment of depression, contributing to more personalized and effective care (Bhaumik, 2023).

In summary, the implementation of machine learning models in mental health shows promising progress in the prediction and diagnosis of mental disorders. However, significant challenges remain related to data quality, systems, and clinical applicability. Continued research and improvement of these models are essential to maximize their accuracy and utility in the treatment of mental health problems, allowing for earlier and more personalized interventions.

Keywords: Mental Health, Machine Learning, Depression, Deep Learning, Mental Disorders.

I. INTRODUCCIÓN

En las últimas décadas, la depresión ha sido reconocida como una de las principales causas de discapacidad a nivel mundial, afectando significativamente la calidad de vida y la productividad de millones de personas (OMS, 2024). En el Perú, los retos asociados a la salud mental son particularmente agudos, con un acceso limitado a servicios especializados y una alta prevalencia de trastornos como la depresión y la ansiedad. Según el Ministerio de Salud del Perú, en 2023 se atendieron más de 280,000 mil casos de depresión en el último año, reflejando una problemática que exige soluciones innovadoras para su diagnóstico y tratamiento oportuno (MINSA, 2024).

En este contexto, es crucial implementar estrategias para mejorar el diagnóstico temprano de la depresión con la finalidad de ofrecer un tratamiento efectivo y mejorar la calidad de vida de las personas. Además, la inteligencia artificial, y en particular los modelos predictivos basados en ML han mostrado un gran potencial en la identificación de patrones y factores de riesgo asociados a trastornos mentales (Sharma, 2021). Asimismo, estudios recientes han demostrado que técnicas como los algoritmos de bosque aleatorio y redes neuronales pueden superar los enfoques convencionales en la predicción de trastornos mentales, logrando altos niveles de precisión y sensibilidad (Castrillón, 2022).

La capacidad de estos algoritmos para automatizar el proceso de diagnóstico contribuye a la optimización de la atención médica, permitiendo intervenciones más tempranas y precisas (Priya, 2020). Sin embargo, la implementación de estos

modelos en sistemas de salud pública enfrenta desafíos significativos, como la falta de datos estructurados y la resistencia al cambio tecnológico por parte de los profesionales de la salud. Asimismo, a pesar de los avances, persisten desafíos relacionados con la generalización y la interpretabilidad de los modelos predictivos. La heterogeneidad de los síntomas depresivos y las diferencias demográficas entre poblaciones limitan la aplicabilidad universal de estos modelos (Lorenzoni, 2024). No obstante, la integración de machine learning en la práctica clínica representa una oportunidad significativa para mejorar la detección temprana y el tratamiento de la depresión, contribuyendo a una atención más personalizada y efectiva (Bhaumik R. S., 2023).

La integración efectiva de herramientas basadas en ML requiere superar estas barreras, asegurando que los modelos sean escalables y adaptables a los contextos específicos de atención primaria (INFOBAE, 2024). Por lo tanto, la presente investigación tiene como objetivo realizar una revisión sistemática sobre la eficacia de los modelos predictivos de ML en el diagnóstico temprano de la depresión, consolidando la evidencia científica disponible y ofreciendo recomendaciones prácticas para su implementación en el sistema de salud pública del Perú.

Además, busca llenar el vacío existente en la literatura y sobre todo contribuir a la literatura existente una visión crítica sobre la eficacia de estos modelos en la optimización del diagnóstico de trastornos de depresión y en el desarrollo de herramientas diagnósticas que permitan a los profesionales de la salud intervenir en las etapas iniciales de la enfermedad.

II. METODOLOGÍA

El presente artículo corresponde a una revisión sistemática que tiene objetivo analizar la eficacia de los modelos predictivos de Machine Learning en el diagnóstico temprano de la depresión, un tema de creciente interés en los ámbitos clínico y tecnológico. Se siguieron las directrices establecidas por el método PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) para garantizar rigor y transparencia en el proceso de revisión (Moher, 2009). Este enfoque es ampliamente reconocido como una herramienta clave en la investigación científica, ya que garantiza la transparencia y reproducibilidad en la selección, evaluación y análisis de los estudios incluidos.

Asimismo, el enfoque de esta revisión responde a la necesidad de consolidar la literatura sobre los avances en ML aplicados al diagnóstico de la depresión, destacando su aplicabilidad en contextos clínicos. La revisión incluye estudios publicados en un periodo comprendido entre 2015 y 2024, con el fin de capturar

el desarrollo reciente de algoritmos predictivos y su validación en entornos de salud pública.

Además, este diseño metodológico permite evaluar tanto los aspectos técnicos (como las métricas de rendimiento de los modelos) como las variables de entrada para procesar los datos, con la finalidad de asegurar su calidad y adecuación (Fahd N. Al-We-sabi, 2022).

2.1. Preguntas de Investigación

Las preguntas realizadas en esta investigación están formuladas en base al enfoque PICO con la finalidad de identificar las variables de estudio y descubrir la utilidad de los aportes más nuevos de los métodos computarizados de ML en el diagnóstico integral de la ansiedad (Ver Tabla 1 - 2).

2.2 Criterios de Selección

En cuanto a los estudios, se seleccionaron en base a los criterios detallados en la Tabla 3.

Tabla 1
Planeamiento de enfoque PICO

Factor	Población (P)	Intervención (I)	Comparación (C)	Objetivo (O)
Detección Temprana	Personas en riesgo de depresión.	Modelos de ML para predicción temprana.	Métodos diagnósticos tradicionales.	Mejorar la sensibilidad, especificidad y precisión en la detección.
Uso de Datos Clínicos	Pacientes con registros clínicos y demográficos disponibles.	Algoritmos de ML para análisis de datos.	Evaluación manual de datos clínicos.	Identificar patrones de riesgo en grandes volúmenes de datos clínicos.
Impacto en el Diagnóstico	Pacientes atendidos en atención primaria.	Herramientas automatizadas de ML.	Diagnóstico tradicional sin apoyo tecnológico.	Incrementar la precisión y rapidez del diagnóstico de la depresión.

Fuente: Elaboración propia.

Tabla 2
Preguntas de investigación

Nº	Pregunta de Investigación
Q1	¿Cuáles son los modelos de Machine Learning más eficaces en la detección de casos tempranos de depresión en comparación con los métodos tradicionales?
Q2	¿En qué medida los modelos de Machine Learning pueden manejar eficientemente grandes volúmenes de datos clínicos para identificar patrones de riesgo asociados a la depresión?
Q3	¿Cómo influye la implementación de modelos predictivos automatizados en la precisión y oportunidad del diagnóstico de la depresión?

Fuente: Elaboración propia.

Tabla 3
Criterios de elegibilidad

Criterio	Criterios de Inclusión	Criterios de Exclusión
Tipo de Estudio	Estudios empíricos y revisiones sistemáticas sobre ML aplicado al diagnóstico de depresión.	Estudios narrativos, opiniones, ensayos sin evidencia empírica sólida, o artículos de revisión no sistemática.
Periodo de Publicación	Publicaciones realizadas entre 2019 y 2024, para capturar los desarrollos recientes en la aplicación de ML en salud mental.	Estudios publicados antes de 2015, a menos que presenten un marco teórico relevante y ampliamente citado en el área de ML aplicado al diagnóstico.
Idioma	Artículos publicados en inglés.	Estudios publicados en otros idiomas sin traducción accesible.
Población	Estudios enfocados en pacientes con diagnóstico de depresión o en riesgo de desarrollar depresión.	Investigaciones que no incluyan poblaciones afectadas por la depresión como foco principal o aquellas centradas en otros trastornos mentales sin relación directa.

Criterio	Criterios de Inclusión	Criterios de Exclusión
Intervención	Estudios que evalúen la implementación de modelos de ML para la predicción, diagnóstico o análisis de la depresión, incluyendo algoritmos como redes neuronales, Random Forest, SVM, entre otros.	Artículos que no utilicen ML como método principal o que lo mencionen de forma tangencial sin evaluar su eficacia en el diagnóstico de la depresión.
Resultados	Investigaciones que incluyan métricas cuantitativas de desempeño (precisión, sensibilidad, especificidad) o análisis comparativos con métodos tradicionales.	Estudios que no reporten métricas cuantitativas claras o que no realicen un análisis de la eficacia de los modelos de ML en el diagnóstico de la depresión.

Fuente: Elaboración propia.

2.3. Estrategia de Búsqueda

Se examinaron tres bases de datos principales: Scopus, Web of Science y ScienceDirect, asimismo se aplicaron filtros para elegir únicamente estudios publicados entre 2019 y la actualidad, lo que significa que se tuvieron en cuenta trabajos de no más de cinco años de antigüedad. Se utilizaron términos clave combinados con operadores booleanos, tales como:

- “Machine Learning” AND “Depresión” AND “Diagnóstico temprano”
- “Predictive Models” AND “Depression” AND “Systematic Review”
- “Predictive Models” AND “Depression” AND “Systematic Review”
- “Machine Learning Algorithms” AND “Mental Health Diagnosis”

Los términos de búsqueda también se identificaron examinando las palabras de los títulos, los resúmenes y la indexación temática de esos registros. Estos términos de búsqueda se validaron mediante herramientas de análisis de frecuencia de palabras en bases de datos académicas.

2.4. Selección de Estudios

El proceso de selección se llevó a cabo en cuatro etapas:


- **Identificación:** Se obtuvieron títulos y resúmenes relevantes mediante la estrategia de búsqueda del cuál se obtuvieron 234 estudios de las tres bases de datos más conocidas: Scopus, Web of Science y ScienceDirect, asimismo se encontraron 26 estudios duplicados en esta identificación.
- **Cribado:** Los títulos y resúmenes se evaluaron de acuerdo a los criterios de selección mencionados en la *tabla 3*.
- **Elegibilidad:** En la elegibilidad de los estudios, se excluyeron 24 documentos los cuales no

tenían relevancia en el contenido textual y no aportaban beneficio alguno.

- **Inclusión:** Los artículos completos seleccionados se analizaron para confirmar su relevancia y calidad metodológica.

Figura 1

Diagrama de flujo prisma



Fuente: Elaboración propia.

2.5. Análisis de Datos

El análisis de los datos en esta revisión sistemática tiene como objetivo sintetizar los hallazgos disponibles en la literatura acerca de la eficacia de los modelos predictivos de ML en el diagnóstico temprano de la depresión. Este análisis ha incluido una evaluación cualitativa y cuantitativa de los resultados presentados en los estudios seleccionados. Asimismo, se han considerado las limitaciones reportadas en los estudios, como la calidad de los datos utilizados, el sesgo de selección y la aplicabilidad de los modelos en contextos clínicos reales (Levin, 2019).

Tabla 4

Investigaciones publicadas

Título de Investigación	Autor(es)	Año	Factores / Dataset	Técnica de ML	Accuracy
Evaluación de ansiedad, depresión y estrés mediante modelos de aprendizaje automático	Prince Kumara, Shruti Garga, Ashwani Gargb	2020	42 preguntas del cuestionario DASS42	La Red de Función de Base Radial (RBFN)	96.02%
Predecir la ansiedad y la depresión en pacientes de edad avanzada mediante tecnología de aprendizaje automático	Arkaprabha Sau1, Ishita Bhakta	2017	Escala de Ansiedad y Depresión Hospitalaria (HADS)	Random Forests	89%
Modelización del comportamiento para la salud mental mediante algoritmos de aprendizaje automático	M. Srividya y S. Mohanavalli y N. Bhalaji	2018	Subconjuntos de características y utilizando el paquete LIME	k-medoids	91%
Predecir problemas de salud mental en la adolescencia mediante técnicas de aprendizaje automático	Ashley E. Tate, Ryan C. McCabe, Henrik Larsson, Sebastian Lundstro, Paul Lichtenstein, Ralf Kuja-Halkola	2020	7,638 gemelos entre Niños y Adolescentes	Random Forests	96%
Mejorar el diagnóstico de la depresión y la ansiedad mediante métodos de aprendizaje automático explicables	Mai Marey, Dina Salem, Nora El Rashidy, Hazem ELBakry	2023	403 mujeres y 380 hombres, con edades entre 18 y 31 años.	Random Forests	94%
Modelo predictivo de la depresión, la ansiedad y el estrés basado en el aprendizaje automático durante la crisis COVID-19	Fahd N. Al-Wesabi, Hadeel Alsolai, Anwer Mustafa Hilal, Manar Ahmed HamzaMesfer, Al Duhayyim y Noha Negrn	2021	DASS-21.	Soporte vectorial (SVM)	95%
Aprendizaje automático aplicado a la prevención y atención de la salud mental en el Perú	Edwin Kcomt Ponce, Melissa Flores Cruz, Laberiano Andrade Arenas	2022	Encuesta estructurada a adultos de diferentes grupos de edad	Redes bayesianas / Análisis de Sentimiento	80%
Predicción de la depresión en estudiantes universitarios utilizando técnicas de apilamiento de conjuntos sobre el método de sobremuestreo	Alfredo Daza Vergaray, Juan Carlos Herrera Miranda, Juana Bobadilla Cornelio, Atilio Ruben Lopez Carranza, Carlos Fidel Ponce Sanchez	2023	Cuestionario de Salud del Paciente-9 (PHQ-9)	Stacking	95%
Predecir la depresión en los habitantes de la comunidad mediante un algoritmo de aprendizaje automático	Seo-Eun Cho, Zong Woo Geem and Kyoung-Sae Na	2021	Cuestionario de Salud del Paciente-9 (PHQ-9)	Regresión Logística	83%
Predicción de ansiedad, depresión y estrés en la vida moderna mediante algoritmos de aprendizaje automático	Anu Priyaa, Shruti Garga, Neha Prerna Tiggaa	2019	Cuestionario DASS-21 (Depression, Anxiety and Stress Scale)	Random Forests	91%

Fuente: Elaboración propia.

III. RESULTADOS

Las preguntas planteadas para esta investigación fueron:

Q1: ¿Cuáles son los modelos de Machine Learning más eficaces en la detección de casos tempranos de depresión en comparación con los métodos tradicionales?

Los modelos de ML han demostrado ser más eficaces que los métodos tradicionales en la detección temprana de la depresión debido a su capacidad para identificar patrones complejos en grandes conjuntos de datos. Por lo cual, diversos estudios han comparado la eficacia de distintos modelos de ML en la detección temprana de depresión frente a métodos tradicionales (Zhang, 2024). A continuación, se destacan algunos hallazgos relevantes de investigaciones previas:

Random Forests (FR): De las investigaciones revisadas, el modelo Random Forests obtuvo una precisión de hasta el 96% en la detección temprana de depresión utilizando datos de síntomas clínicos y entrevistas estandarizadas, superando el 75% de precisión de los métodos tradicionales como cuestionarios manuales.

Support Vector Machines (SVM): Se encontraron estudios con métodos de SVM y Redes Neuronales Profundas (DNN) superando a los diagnósticos convencionales al lograr una mayor precisión (95%) en la identificación de indicadores fisiológicos de depresión mostrando una alta capacidad para capturar patrones complejos en datos clínicos.

Naïve Bayes: Este modelo, logró una precisión de hasta 80% en algunos estudios, siendo eficaz para datos con una estructura más sencilla y con menores volúmenes de datos.

En la **Figura 2**, se muestra como estos modelos de ML han superaron significativamente a métodos tradicionales, como el uso de cuestionarios tipo PHQ-9 y entrevistas clínicas estándar, los cuales presentaban una precisión promedio entre 70% y 75%.


Q2: ¿En qué medida los modelos de Machine Learning pueden manejar eficientemente grandes volúmenes de datos clínicos para identificar patrones de riesgo asociados a la depresión?

Los modelos de ML están diseñados para procesar grandes volúmenes de datos clínicos y detectar

patrones complejos asociados a factores de riesgo de depresión. En algunas de estas investigaciones, se aplicaron técnicas como Random Forest y Gradient Boosting para analizar datos multivariados (historial médico, datos demográficos y respuestas a cuestionarios). Estas técnicas permiten identificar correlaciones y factores de riesgo específicos,


como antecedentes familiares, comorbilidades y puntuaciones en escalas de depresión (Aleem S. H., 2022). Además, el uso de técnicas de procesamiento de lenguaje natural (NLP) ha facilitado el análisis automatizado de registros médicos electrónicos para detectar signos tempranos de depresión (ver Figura 3).

Figura 2
Comparación de Modelos de Machine Learning



Fuente: Elaboración propia.

Figura 3
Matriz de correlación de Factores de Riesgo



Fuente: Elaboración propia.

Q3: ¿Cómo influye la implementación de modelos predictivos automatizados en la precisión y oportunidad del diagnóstico de la depresión?


El enfoque empleado en las investigaciones revisadas se puede apreciar la influencia para identificar patrones complejos en los datos, que resultan útiles para predecir la depresión y otros trastornos mentales. Además mejoran significativamente la precisión y rapidez del diagnóstico de la depresión.

Los modelos como el Support Vector Machine (SVM), Naive Bayes, árboles de decisión, K vecino y Random Forest han permitido diagnósticos con una precisión superior al 90% en tiempos mucho más reducidos que los métodos tradicionales, facilitando intervenciones tempranas, alcanzando altas tasas de precisión (Aleem S. H., 2022). Además, estos modelos han ayudado a reducir el sesgo subjetivo del diagnóstico clínico, proporcionando evaluaciones más objetivas y consistentes.

Por otro lado, ciertos estudios de esta revisión integran plataformas de telemedicina con la finalidad de llevar estas herramientas a entornos remotos, mejorando la accesibilidad y oportunidad del diagnóstico. Asimismo, algunos estudios de estos últimos años, refuerzan la influencia de algoritmos de aprendizaje automático debido a su capacidad para analizar grandes volúmenes de datos y generar predicciones precisas sobre el estado de salud mental de los individuos (Priya, 2020).

Figura 4

Influencia y tiempo promedio diagnósticos



Fuente: Elaboración propia.

4. DISCUSIÓN

La implementación de modelos de ML para el diagnóstico temprano de la depresión representa una

mejora significativa en comparación con los métodos tradicionales. Estos modelos ofrecen una precisión diagnóstica notablemente superior, permitiendo identificar patrones de riesgo complejos que serían difíciles de detectar con cuestionarios y evaluaciones subjetivas. Esta eficacia se debe a la capacidad de los algoritmos para procesar grandes volúmenes de datos clínicos y encontrar correlaciones no evidentes a simple vista. Mientras que los métodos tradicionales, como los cuestionarios PHQ-9 o evaluaciones psiquiátricas estándar, dependen de la interpretación del profesional y del autoinforme del paciente, los modelos predictivos automatizados ofrecen una evaluación objetiva basada en datos cuantificables.

Además, los modelos de ML como Random Forest, Redes Neuronales, Support Vector Machines (SVM) y algoritmos de clasificación como Naïve Bayes, han demostrado una capacidad sobresaliente para manejar grandes cantidades de datos provenientes de múltiples fuentes, como registros médicos electrónicos, datos sociodemográficos y resultados de pruebas psicológicas. Esta capacidad de procesamiento permite identificar factores de riesgo sutiles y establecer correlaciones que facilitan un diagnóstico más temprano y preciso. La posibilidad de combinar diferentes tipos de datos aumenta aún más la precisión y adaptabilidad de los modelos a distintos contextos clínicos y poblacionales.

Por otro lado, la implementación de estas tecnologías reduce considerablemente el tiempo necesario para realizar un diagnóstico. A diferencia de los métodos tradicionales, que dependen de la disponibilidad y capacidad de atención del personal de salud, los modelos de ML pueden analizar datos en tiempo real y ofrecer diagnósticos automatizados de manera inmediata. Esto no solo permite atender una mayor cantidad de pacientes en menos tiempo, sino que también facilita intervenciones tempranas, evitando que los síntomas se agraven por falta de atención oportuna.

Sin embargo, a pesar de los avances y beneficios evidentes, existen desafíos importantes que deben considerarse. Uno de los principales retos es la interpretabilidad de los modelos de ML. Las técnicas más avanzadas, como las redes neuronales profundas, son difíciles de interpretar, lo que puede generar resistencia entre los profesionales de la salud y dificultar su adopción en entornos clínicos. Además, la calidad de los datos es un factor crucial para el éxito de estos modelos. Datos incompletos, desactualizados o con sesgos pueden llevar a diagnósticos erróneos, afectando la confiabilidad del sistema.

Otro desafío es la infraestructura tecnológica necesaria para implementar estos sistemas en los servicios de salud pública, especialmente en países como Perú, donde el acceso a tecnologías avanzadas y la capacitación del personal pueden ser limitados. Superar estas barreras requiere una inversión en capacitación continua, mejora de la infraestructura tecnológica y políticas que faciliten la integración de estas herramientas en la práctica clínica.

Finalmente, el uso de modelos predictivos automatizados también plantea preocupaciones éticas y de privacidad de los datos. Es fundamental garantizar que los datos utilizados estén protegidos y que los pacientes comprendan cómo se emplea su información. La implementación de marcos éticos y normativas adecuadas es esencial para asegurar un uso responsable y seguro de estas tecnologías.

5. CONCLUSIONES

Los hallazgos más significativos de esta revisión sistemática muestran que Random Forests, los bosques aleatorios, las regresiones logísticas, las máquinas de soporte vectorial, las redes neuronales y los árboles de decisión son algunas de las técnicas de aprendizaje automático más populares para predecir la depresión. Al clasificar el riesgo de cada persona de desarrollar algún trastorno de depresión, estas técnicas permiten un enfoque variado para el manejo de la enfermedad, ya que se daría prioridad al manejo y se implementaría una estrategia preventiva diferenciada.

Asimismo, aunque existen sistemas de evaluación de la depresión, estos son principalmente de naturaleza cualitativa y pueden estar sesgados por la percepción individual. No hay ninguna prueba de técnicas estadísticas rigurosas que permitan clasificar con precisión las distintas etapas de la depresión.

En conclusión, la aplicación de ML en el diagnóstico temprano de la depresión ofrece una oportunidad valiosa para mejorar la precisión, eficiencia y oportunidad en la detección de esta condición de salud mental. A medida que se superan los desafíos tecnológicos y éticos, estos modelos tienen el potencial de transformar significativamente la atención en salud mental, especialmente en contextos de atención primaria, donde el diagnóstico temprano es crucial para un tratamiento efectivo y una mejor calidad de vida para los pacientes.

REFERENCIAS

- [1] Aleem, S. H. (2022). Machine Learning Algorithms for Depression: Diagnosis, Insights, and Research Directions. *Electronics*, 11(7). doi: <https://doi.org/10.3390/electronics11071111>
- [2] Aleem, S. H. (2022). Machine Learning Algorithms for Depression: Diagnosis, Insights, and Research Directions. *Electronics*, 11(7). doi: <https://doi.org/10.3390/electronics11071111>
- [3] Al-Wesabi, F. N. (2022). Machine Learning Based Depression, Anxiety, and Stress Predictive Model During COVID-19 Crisis. *Computers, Materials & Continua*, 5803-5820. doi: <https://doi.org/10.32604/cmc.2022.021195>
- [4] Castrillón, S. O. (2022). Machine learning aplicado en la clasificación y predicción de la depresión: Una revisión sistemática. *RISTI - Revista Ibérica de Sistemas e Tecnologías de Información*, 363-375.
- [5] Choudhury, A. A. (2019). Predicting Depression in Bangladeshi Undergraduates using Machine Learning. *IEEE International Symposium on Technology and Society (ISTAS)*, 789 - 794. doi: <https://doi.org/10.1109/TENSYP46218.2019.8971369>
- [6] Chung, J. T. (2022). Mental Health Prediction Using Machine Learning: Taxonomy, Applications, and Challenges. *Journal of Machine Learning and Health*, 1-15. doi: [10.1155/2022/9970363](https://doi.org/10.1155/2022/9970363)
- [7] Eduardo Jáuregui, C. T. (2023). Desarrollo de un algoritmo supervisado para la clasificación de distritos según la prevalencia de problemas mentales en su población. *Revista de investigación de sistemas e informática de la UNMSM*, 5 - 13. doi: [10.15381/risi.v16i2.25774](https://doi.org/10.15381/risi.v16i2.25774)
- [8] Fahd N. Al-Wesabi, H. A. (2022). Modelo predictivo de depresión, ansiedad y estrés basado en aprendizaje automático durante la crisis de COVID-19. *Tech Science Press*, 5803-5820. doi: [10.32604/cmc.2022.021195](https://doi.org/10.32604/cmc.2022.021195)
- [9] INFOBAE. (2024). <https://www.infobae.com/peru/>. Obtenido de <https://www.infobae.com/peru/>: <https://www.infobae.com/peru/>
- [10] Katarya, R. &. (2020). Predicting Mental health disorders using Machine Learning for employees in technical and non-technical companies. *2020 IEEE INTERNATIONAL CONFERENCE*

- ON ADVANCES AND DEVELOPMENTS IN ELECTRICAL AND ELECTRONICS ENGINEERING (ICADEE 2020). doi: 10.1109/ICADEE51157.2020.9368923
- [11] Levin, M. E. (2019). Improving depression screening with technology: Advances and limitations of machine learning. *Journal of Affective Disorders*, 439–445. doi: <https://doi.org/10.1016/j.jad.2019.02.021>
- [12] Masco, H. V. (2020). *Predicción del nivel de estrés en estudiantes universitarios utilizando técnicas de machine learning*. Juliaca: Universidad Peruana Unión.
- [13] Matthew, N. &. (2021). Modelado predictivo de la depresión y la ansiedad mediante registros médicos electrónicos y un novedoso enfoque de aprendizaje automático con IA. *Revista de Sistemas*, 0.
- [14] MINSA. (Abril de 2023). *Perú 21*. Obtenido de <https://peru21.pe/lima/salud-mental-minsa-depresion-ansiedad-estres-preocupante-en-los-primeros-tres-meses-de-2023-se-han-atendido-434731-casos-vinculados-a-salud-mental-noticia/>
- [15] MINSA. (2024). Obtenido de <https://www.gob.pe>
- [16] Moher, D. L. (2009). Preferred reporting items for systematic reviews and meta-analyses: The PRISMA statement. 7. doi: <https://doi.org/10.1371/journal.pmed.1000097>
- [17] Nemesure, M. D. (2021). Predictive modeling of depression and anxiety using electronic health records and a novel machine learning approach with artificial intelligence. *Scientific Reports*. doi: 10.1038/s41598-021-81368-4
- [18] Nemesure, M. D., Heinz, M. V., Huang, R., & Jacobson, N. C. (2021). Predictive modeling of depression and anxiety using electronic health records and a novel machine learning approach with artificial intelligence. *Scientific reports*, 11.
- [19] Nickson, D. M. (2023). Prediction and diagnosis of depression using machine learning with electronic health records data: A systematic review. *BMC Medical Informatics and Decision Making*. doi: <https://doi.org/10.1186/s12911-023-02341-x>
- [20] OMS. (2024). <https://www.who.int/es>. Obtenido de <https://www.who.int/es>: <https://www.who.int/es>
- [21] Orué Medina, A. M. (2018). *Detección de depresión a través de análisis textual utilizando Machine Learning*. Lima - Perú: Universidad Ricardo Palma.
- [22] Priya, A. G. (2020). Predicting Anxiety, Depression and Stress in Modern Life using Machine Learning Algorithms. *Procedia Computer Science*, 1258 - 1267. doi: 10.1016/j.procs.2020.03.442
- [23] ROHIZAH ABD RAHMAN, O. K.-G. (2020). Application of Machine Learning Methods in Mental Health Detection: A Systematic Review. *IEEE Access*, 183252 - 183964. doi: 10.1109/ACCESS.2020.3029154
- [24] Sharma, H. G. (2021). Predictive modeling for mental health assessment using machine learning: A systematic review. *Journal of Biomedical Informatics*, 117.
- [25] Srividya, M. M. (2023). Modelización del comportamiento para la salud mental mediante algoritmos de aprendizaje automático. *Revista de Sistemas Médicos*, 42(5). doi: 10.1007/s10916-018-0934-5
- [26] Tate, A. E.-H. (2020). Predicting mental health problems in adolescence using machine learning techniques. *PLOS ONE*, 1-13. doi: 10.1371/journal.pone.0230389
- [27] Zhang, J. Z. (2024). Electroencephalogram Depression Diagnosis Based on Traditional Machine Learning and Deep Learning: A Comparative Analysis. *Sensors*, 24(21). doi: <https://doi.org/10.3390/s24216815​>