

## Nota

# Possibles aplicaciones prácticas del uso de *Machine Learning (ML)* en la investigación y práctica de la clínica psicológica

LORENA CECILIA LÓPEZ STEINMETZ, JUAN CARLOS GODOY

LORENA Cecilia López Steinmetz  
Doctora en Psicología.  
Instituto de Investigaciones  
Psicológicas,  
Universidad Nacional de  
Córdoba, Consejo Nacional de  
Investigaciones Científicas y  
Técnicas, Córdoba,  
R. Argentina.  
(IIPsi - UNC - CONICET).  
Córdoba,  
R. Argentina.  
Technische Universität Berlin,  
Berlín, Alemania. (TU Berlin).  
Berlín, R. de Alemania.

JUAN CARLOS GODOY  
Doctor en Psicología.  
Instituto de Investigaciones  
Psicológicas,  
Universidad Nacional de  
Córdoba, Consejo Nacional de  
Investigaciones Científicas y  
Técnicas, Córdoba, Argentina.  
(IIPsi - UNC - CONICET).  
Córdoba, R. Argentina.

FECHA DE RECEPCIÓN: 01/09/2023  
FECHA DE ACEPTACIÓN: 27/10/2023

CORRESPONDENCIA  
Dra. Lorena Cecilia López  
Steinmetz.  
Marchstraße 23, 4to piso,  
oficina 4.0019. Berlín,  
CP 10587, R. de Alemania;  
cecilialopezsteinmetz@unc.edu.ar

En este artículo se analiza el impacto, potencialidades, desafíos y perspectivas a futuro del uso de algoritmos de *Machine Learning (ML)* en psicología clínica, con un enfoque en la investigación básica y la aplicación clínica. El ML está transformando la investigación y práctica clínica, al analizar datos complejos y descubrir patrones para la comprensión de trastornos mentales y la predicción de diagnósticos, entre otros aspectos destacables. A pesar de los desafíos de interpretación, privacidad y sesgo, se reconoce el potencial transformador de los algoritmos de ML en la psicología clínica. La colaboración interdisciplinaria es esencial para maximizar estos beneficios. Se subraya la importancia de abordar consideraciones éticas y prácticas. En última instancia, se anticipa un futuro en el que los algoritmos de ML sean herramientas integrales en la investigación, diagnóstico y tratamiento de los trastornos mentales, contribuyendo a una mejora global en la calidad de vida de las personas.

**Palabras clave:** Análisis de datos – Predicción – Inteligencia artificial – Trastornos mentales – Investigación translacional.

## Potential Practical Applications of the Use of Machine Learning (ML) in Psychological Research and Clinical Practice

This article examines the impact, potentials, challenges, and future prospects of using Machine Learning (ML) algorithms in clinical psychology, with a focus on basic research and clinical application. ML is reshaping both research and clinical practice by analyzing complex data and uncovering patterns for understanding mental disorders and predicting diagnoses, among other noteworthy aspects. Despite the challenges of interpretation, privacy, and bias, the transformative potential of ML algorithms in clinical psychology is acknowledged. Interdisciplinary collaboration is essential to maximize these benefits. Emphasizing the importance of addressing ethical and practical considerations, this paper envisions a future where ML algorithms become integral tools in the research, diagnosis, and treatment of mental disorders, contributing to an overall enhancement in people's quality of life.

**Keywords:** Data Analysis – Prediction – Artificial Intelligence – Mental Disorders – Translational Research.

## Introducción

La psicología clínica, como disciplina fundamental en el ámbito de la salud mental, se dedica al estudio, diagnóstico, tratamiento y prevención de los trastornos mentales y emocionales que afectan a los individuos. Su enfoque abarca no solo la comprensión profunda de los procesos psicológicos subyacentes a estos trastornos, sino también la búsqueda de estrategias terapéuticas efectivas para aliviar el sufrimiento psicológico y mejorar la calidad de vida de las personas. A medida que la psicología clínica ha evolucionado, ha ido reconociendo la importancia de la prevención de los trastornos mentales, trabajando para identificar factores de riesgo y promover la salud mental en las poblaciones. En un contexto global donde la carga de enfermedades mentales es significativa, la psicología clínica adquiere una relevancia crucial al brindar herramientas para mejorar la calidad de vida y el bienestar psicológico de las personas [3, 38].

La incorporación de la tecnología, incluyendo los algoritmos de *Machine Learning* (ML; en español: aprendizaje automático), ha comenzado a transformar la manera en que la psicología clínica aborda sus objetivos y desafíos [1, 37]. En particular, los avances en algoritmos de ML han aportado nuevas posibilidades para el análisis y la interpretación de los datos clínicos. Aunque es cierto que el uso de ML en la disciplina psicológica aún está en desarrollo y su implementación en la práctica clínica varía según la región y el nivel de desarrollo tecnológico, su potencial para revolucionar la investigación y la práctica clínica es innegable [1, 37]. A través del análisis de datos complejos y la identificación de patrones en grandes conjuntos de información, los algoritmos de ML tienen el poder de proporcionar conocimientos profundos y valiosos en el estudio de la mente humana [ver, e.g., 5, 14].

Así, en este artículo se aborda la temática del uso de algoritmos de ML en el campo de la psicología clínica, un tema que ha sido poco explorado en la literatura académica de América Latina. Reconociendo la escasez de producción sobre el tema en esta región, en el artículo se ofrece una introducción simple y accesible, proporcionando una visión general del ML y sus posibles aplicaciones en el ámbito de la psicología clínica, con el propósito de sentar las bases para futuras investigaciones y discusiones en esta área de interés. Además, se analiza el impacto, las potencialidades, los desafíos y perspectivas a futuro del uso de algoritmos de ML en el campo de la psicología clínica, centrándose en sus aplicaciones tanto en la investigación básica como en la psicología clínica aplicada.

A pesar de las diferencias en la adopción de estas tecnologías en diferentes regiones, es fundamental reconocer que el potencial de los algoritmos de ML para mejorar la comprensión, prevención y tratamiento de los trastornos mentales es relevante en una perspectiva global. A medida que en este artículo se examinan sus usos, beneficios y desafíos, también se consideran las perspectivas futuras que podrían llevar a una implementación más amplia y efectiva en el campo de la psicología clínica.

## Relevancia de los algoritmos de *Machine Learning* en psicología clínica

En el marco de la psicología clínica, la explosión de datos generados ha elevado la necesidad de métodos analíticos más sofisticados para comprender la complejidad de los trastornos mentales y emocionales. La acumulación de información proveniente de diversas fuentes, que van desde sesiones de terapia hasta tecnologías de seguimiento y monitoreo, e incluso el aumento de los problemas de salud mental durante la pandemia de COVID-19, ha presentado tanto un desafío como una oportunidad para la investigación y la práctica clínica. En este contexto, los algoritmos de ML han emergido como una herramienta esencial que supera las limitaciones de los análisis de datos tradicionales, permitiendo una exploración más profunda y significativa [34].

El ML es una rama de la inteligencia artificial que se centra en el desarrollo de algoritmos y modelos que permite a las máquinas aprender de los datos y mejorar su rendimiento en tareas específicas con experiencia acumulada. En esencia, los algoritmos de ML son sistemas computacionales diseñados para aprender de los datos y mejorar su rendimiento con la experiencia. Estos algoritmos permiten a las *máquinas* reconocer patrones y relaciones en datos complejos, mediante la identificación de características relevantes y, a través de la exposición a ejemplos previos, pueden ajustar sus parámetros para hacer predicciones y tomar decisiones, es decir, formular modelos predictivos [6, 19, 26, 31]. En el contexto de la psicología clínica, esto implica que los algoritmos de ML pueden procesar y analizar grandes conjuntos de información con el objetivo de descubrir patrones y tendencias [22, 26], incluso aquellos que podrían pasar desapercibidos con análisis convencionales. Tales patrones y tendencias también pueden pasar desapercibidos para los análisis estadísticos tradicionalmente utilizados en psicología clínica [14], tales como el análisis de diferencias, correlaciones y modelos de efectos mixtos, entre otros, ya que estos análisis no están específicamente diseñados para realizar predicciones en

contextos complejos. Por ejemplo, los modelos de efectos mixtos están diseñados principalmente para hacer inferencia más que para realizar predicción y ofrecen una flexibilidad limitada para el manejo de datos complejos de alta dimensión, lo que limita su precisión predictiva en comparación con los modelos de ML. En cambio, los algoritmos de ML pueden manejar cantidades de datos enormes, incluso en el orden de millones o más de registros, y trabajar con características altamente complejas y no lineales. Por ejemplo, un estudio que caracterizó las condiciones de salud mental de usuarios de redes sociales aplicando *Deep Learning* analizó los datos de 234 millones de usuarios y detectó con alta precisión (91 % de precisión) las publicaciones relacionadas con enfermedades mentales [17]. Por otra parte, los métodos estadísticos clásicos están orientados a determinar la significancia de las relaciones y diferencias identificadas en los datos, así como a establecer la magnitud y dirección de las asociaciones. En otras palabras, se enfoca principalmente en la comprensión de la estructura de los datos y la evaluación de diferencias, en lugar de anticipar resultados futuros o identificar tendencias en datos no evidentes a simple vista. Sin embargo, estos análisis estadísticos tradicionalmente utilizados en psicología clínica carecen de la capacidad intrínseca de los algoritmos de ML para descubrir patrones sutiles y complejos presentes en grandes conjuntos de datos. Los algoritmos de ML están concebidos para extraer información oculta y potenciar la capacidad predictiva mediante la identificación de relaciones no lineales y conexiones complejas que podrían pasarse por alto con enfoques tradicionales [6, 19, 26, 31].

En resumen, los métodos estadísticos convencionales son esenciales para establecer relaciones y diferencias, pero carecen de la capacidad de predicción inherente a los algoritmos de ML. Estos últimos son diseñados para descubrir patrones profundos y generar modelos predictivos, lo que los convierte en herramientas fundamentales para el avance de la psicología clínica.

Existen diversas categorías de ML según la naturaleza de las tareas que pueden llevar a cabo:

1. *Aprendizaje supervisado*: este tipo implica entrenar algoritmos utilizando un conjunto de datos etiquetado, donde se conocen las respuestas correctas. Los algoritmos pueden aprender a mapear entradas a salidas a través de ejemplos previos. Son ampliamente utilizados en la clasificación y predicción, como la identificación de diagnósticos con base en síntomas o en la predicción de resultados de tratamientos. Algoritmos de aprendizaje supervisado se han usado para

desarrollar y evaluar modelos de predicción de intentos suicidas en adolescentes [28] y para predecir el diagnóstico de depresión en estudiantes universitarios [29]. Algunos ejemplos de algoritmos de aprendizaje supervisado utilizados en psicología clínica son: regresión logística, máquinas de soporte vectorial (SVM), árboles de decisión y bosques aleatorios [7, 12, 19].

2. *Aprendizaje no supervisado*: en este caso, los algoritmos encuentran patrones en datos no etiquetados, agrupándolos en categorías similares. Esto es útil para descubrir relaciones entre variables que podrían no ser evidentes para los investigadores. Puede usarse en psicología clínica para identificar grupos de pacientes con características similares. Por ejemplo, mediante *K-Means Clustering* se pueden agrupar pacientes con perfiles clínicos afines, e.g., esquizofrenia crónica, permitiendo tratamientos más personalizados y eficaces [8]. Ejemplos de algoritmos son: el mencionado *K-Means Clustering* y análisis de componentes principales (PCA) [19].

3. *Redes neuronales artificiales*: inspiradas en el funcionamiento del cerebro humano, estas redes están compuestas por unidades interconectadas llamadas neuronas artificiales. Pueden aprender patrones complejos a partir de datos y se aplican en áreas como el procesamiento de imágenes, donde pueden detectar características específicas en imágenes médicas. Algoritmos de redes neuronales se utilizaron, e.g., para calificar la depresión en adultos [10]. Ejemplos de este tipo de algoritmos son: redes neuronales convolucionales (CNN) para análisis de imágenes y redes neuronales recurrentes (RNN) para análisis de secuencias [19, 24].

4. *Aprendizaje profundo* (*Deep Learning*): esta categoría utiliza redes neuronales con múltiples capas para aprender representaciones de datos de manera jerárquica. Es especialmente adecuado para datos de alta dimensión y se ha destacado en la detección de patrones complejos en secuencias de ADN o imágenes cerebrales. Por ejemplo, se utilizó para diagnosticar trastornos del espectro autista usando imágenes cerebrales [32] y para detectar a aquellos usuarios de redes sociales que manifestaron haber sido diagnosticados previamente con depresión [30]. Ejemplos de estos algoritmos son: redes neuronales convolucionales profundas (*Deep CNN*) y redes neuronales recurrentes profundas (*Deep RNN*) [18, 27].

La explicación de cada uno de los algoritmos de ML excede a los límites de este escrito. No obstante, es importante mencionar que la selección

adecuada del algoritmo de ML depende de la tarea específica y del tipo de datos con los que se esté trabajando. Cada uno de estas categorías ofrece ventajas y desafíos particulares, y la elección correcta puede tener un impacto significativo en la calidad de los resultados obtenidos en la investigación y la práctica clínica.

Dada la naturaleza multidimensional y compleja de los datos en psicología clínica se resalta la importancia de las técnicas de ML para revelar relaciones subyacentes y generar nuevos conocimientos. Al aplicar algoritmos de ML, los y las profesionales en psicología clínica pueden profundizar en la comprensión de los trastornos mentales y, en última instancia, desarrollar enfoques más personalizados y efectivos para el diagnóstico y el tratamiento [37].

### **Perspectivas de desarrollo en psicología clínica**

El potencial de los algoritmos de ML en psicología clínica es vasto y prometedor [35]. A medida que se acumulan más datos y se refinan los algoritmos, es plausible anticipar un futuro en el que las herramientas de ML sean una parte integral de la práctica clínica. Además de su uso en la investigación, los algoritmos de ML tienen el potencial de informar la toma de decisiones clínicas y proporcionar una base sólida para el desarrollo de políticas sanitarias basadas en evidencia en el ámbito de la salud mental [1, 2, 16].

La integración exitosa de algoritmos de ML en la psicología clínica podría generar un cambio de paradigma en la forma en que se abordan los trastornos mentales. Por ejemplo, los algoritmos de ML pueden ser utilizados para identificar patrones tempranos de riesgo en poblaciones vulnerables, permitiendo la detección temprana y preventión de trastornos mentales antes de que se manifiesten por completo [ver, e.g., 13]. Esta capacidad de predicción [37] tiene el potencial de reducir la carga de enfermedades mentales al intervenir de manera temprana y efectiva. Por ejemplo, en el caso de la depresión, se demostró que algunos algoritmos de ML pueden examinar patrones en el comportamiento de las personas basado en diferentes aspectos de sus escritos en redes sociales, tales como extensión textual, intervalo de tiempo y lapso de tiempo, e identificar señales de alarma tempranas, que pueden ayudar a la detección de la depresión [9]. Esto, su vez, posibilitaría intervenciones más tempranas y eficaces.

Además, el uso de algoritmos de ML puede mejorar la precisión en el diagnóstico [ver, e.g., 23] y la selección de tratamientos personalizados [37]. Al analizar una variedad de datos, como síntomas,

características genéticas y respuestas a tratamientos anteriores, los algoritmos pueden ayudar a los y las profesionales de la psicología clínica a tomar decisiones más informadas y efectivas sobre la terapia adecuada para cada paciente. Esto puede resultar en tratamientos más efectivos y una mayor tasa de éxito en la recuperación [35]. Además, las tecnologías de ML pueden mejorar la monitorización de los pacientes a lo largo del tiempo, permitiendo una adaptación continua de los tratamientos en función de la respuesta individual [ver, e.g., 15].

En cuanto al desarrollo de políticas sanitarias, la implementación de algoritmos de ML puede permitir una toma de decisiones basada en evidencia sólida y en tiempo real [25]. Al analizar datos a gran escala sobre la prevalencia de trastornos mentales, los factores de riesgo y los resultados de intervenciones, los algoritmos de ML pueden identificar patrones y tendencias que ayudan a informar políticas que sean más efectivas y pertinentes para las necesidades de la población [4]. Por ejemplo, se pueden entrenar algoritmos de ML con datos clínicos existentes para la identificación prospectiva de pacientes que probablemente respondan a un tratamiento específico [ver, e.g., 11].

Sin embargo, es importante abordar los desafíos asociados con la implementación de algoritmos de ML en la práctica clínica. La confidencialidad y la privacidad de los datos de los pacientes deben ser protegidas de manera rigurosa, y se deben abordar precauciones éticas relacionadas con la toma de decisiones automatizadas [1, 36]. Además, los problemas de interpretabilidad en algunos modelos y técnicas de ML [ver, e.g., 20] puede ser un obstáculo para su adopción en entornos clínicos.

### **Desafíos y consideraciones éticas en la aplicación de algoritmos de *Machine Learning* en psicología clínica**

#### *Complejidad en la interpretación de resultados*

A pesar de las ventajas evidentes, la aplicación de algoritmos de ML en psicología clínica no está exenta de desafíos y límites. Uno de los principales obstáculos radica en la interpretación de los resultados generados por los algoritmos. A medida que los algoritmos procesan y analizan datos de manera automatizada, pueden identificar patrones y relaciones complejas que a menudo no son evidentes para los y las profesionales de la salud mental. La interpretación precisa de estos resultados puede requerir un alto nivel de experiencia en estadísticas y ciencia de datos, lo que puede dificultar la traducción efectiva de los hallazgos a la práctica clínica [21].

### *Privacidad y seguridad de los datos de los y las pacientes*

Otro desafío crítico se relaciona con la privacidad y seguridad de los datos de los y las pacientes. La recopilación y el análisis de datos clínicos sensibles plantean preocupaciones éticas y legales sustanciales. Los algoritmos de ML deben operar en un entorno seguro y protegido para garantizar la confidencialidad de la información del paciente [1, 11]. Además, la anonimización y el manejo adecuado de los datos son aspectos fundamentales para evitar la filtración de información personal y mantener la confianza de los y las pacientes en la aplicación de estas tecnologías.

### *Sesgo y generalización de resultados*

Una inquietud relevante en la implementación de algoritmos de ML en psicología clínica es el riesgo de sesgos inherentes en los datos con los que son entrenados. Si los datos de entrenamiento contienen sesgos o prejuicios, es altamente probable que los algoritmos reproduzcan y amplifiquen estos sesgos en sus resultados [33]. Esto podría tener consecuencias significativas en el diagnóstico y tratamiento de los trastornos mentales, ya que los algoritmos podrían perpetuar desigualdades en el cuidado de la salud mental. Por lo tanto, es crucial abordar activamente el sesgo en los datos que se utilizan para entrenar los algoritmos de ML y desarrollar estrategias para garantizar resultados justos y equitativos [21].

### *Perspectivas futuras y consideraciones*

A medida que avanzamos hacia un futuro en el que los algoritmos de ML se integren más en la psicología clínica, es fundamental abordar las consideraciones éticas y prácticas que rodean su implementación. La transparencia en la toma de decisiones basada en algoritmos y la protección de la privacidad de los datos de los y las pacientes son aspectos cruciales que deben abordarse de manera rigurosa. Sin embargo, existen otras perspectivas y consideraciones igualmente importantes que deben ser discutidas para lograr una integración efectiva y beneficiosa de los algoritmos de ML en el ámbito de la salud mental.

**Colaboración interdisciplinaria:** una perspectiva clave para el desarrollo futuro de la psicología clínica es la necesidad de una colaboración interdisciplinaria más profunda. La aplicación exitosa de algoritmos de ML requiere la colaboración entre profesionales de la salud mental, científicos de datos, ingenieros informáticos y expertos en ética, entre otros. La combinación de conocimientos y habilidades de diferentes disciplinas puede enriquecer la implementación de estas tecnologías y

garantizar que se aborden todas las dimensiones relevantes, desde la precisión de los algoritmos hasta la consideración de aspectos éticos y legales.

**Evaluación y validación continuas:** a medida que se desarrollan nuevos algoritmos de ML y se implementan en la práctica clínica, es fundamental establecer procesos continuos de evaluación y validación. La evolución constante de la psicología clínica y la naturaleza cambiante de los trastornos mentales requieren una adaptación constante de los algoritmos de ML. La investigación rigurosa y la validación empírica son esenciales para garantizar que los algoritmos sigan siendo precisos, efectivos y éticamente sólidos a lo largo del tiempo.

**Equidad en el acceso:** otra consideración importante es la equidad en el acceso a las tecnologías de ML en psicología clínica. Dado que la implementación exitosa de estas tecnologías puede requerir recursos financieros y tecnológicos, es crucial abordar las disparidades en el acceso. La falta de acceso equitativo podría exacerbar las desigualdades en el cuidado de la salud mental en poblaciones vulnerables. Por lo tanto, es esencial diseñar estrategias que garanticen que las ventajas de los algoritmos de ML estén disponibles para todas las personas, independientemente de su situación socioeconómica. En el mismo sentido, es esencial diseñar estrategias de financiamiento y formación que garanticen que las ventajas de los algoritmos de ML estén disponibles para ser utilizados en investigaciones conducidas no sólo en países desarrollados [37] sino también en países en vías de desarrollo, tales como los países de Sudamérica.

En resumen, el futuro de la psicología clínica con la integración de algoritmos de ML es prometedor, pero también plantea desafíos significativos. A medida que se producen avances, es vital tener en cuenta y abordar estas perspectivas y consideraciones clave para garantizar que estas tecnologías se utilicen de manera efectiva, ética y beneficiosa para mejorar la salud mental y el bienestar de las personas.

### **Conclusión**

El presente artículo, exploró el impacto y las perspectivas de la aplicación de algoritmos de ML en el campo de la psicología clínica, tanto desde una perspectiva de investigación básica como aplicada. A medida que la psicología clínica, como disciplina esencial en el ámbito de la salud mental, se enfrenta a desafíos complejos en el estudio, diagnóstico, prevención y tratamiento de los trastornos mentales, los avances tecnológicos en forma de

algoritmos de ML han surgido como una poderosa herramienta con el potencial de transformar tanto la investigación básica como la psicología clínica aplicada.

Se resaltó cómo los algoritmos de ML permiten el análisis eficiente de grandes conjuntos de datos, la identificación de patrones ocultos y la generación de conocimientos profundos en el estudio de la mente humana. Estos algoritmos se han aplicado con éxito en áreas como la predicción de diagnósticos, la detección de patrones en imágenes cerebrales y el descubrimiento de relaciones entre variables que antes pasaban desapercibidas.

Sin embargo, no se han ignorado los desafíos que esta integración plantea. Desde la interpretación precisa de los resultados hasta la consideración de aspectos éticos y de privacidad, la adopción de algoritmos de ML en la práctica clínica requiere un enfoque riguroso y reflexivo. Los sesgos inherentes en los datos, la seguridad de la información de los y las pacientes y la equidad en el acceso son aspectos cruciales que deben abordarse para maximizar los beneficios de esta tecnología.

Las perspectivas futuras también se han destacado en este artículo. La colaboración interdisciplinaria, la adaptación constante de los algoritmos y la búsqueda de equidad en el acceso son pilares fundamentales para el desarrollo continuo de la psicología clínica basada en algoritmos de ML. A medida que se producen avances en este campo, es crucial mantener un enfoque centrado en la ética y en la mejora del bienestar de las personas.

En última instancia, este artículo resalta la importancia de considerar el potencial transformador de los algoritmos de ML en la psicología clínica. Aunque los desafíos son reales, el futuro se presenta lleno de oportunidades para mejorar la investigación, el diagnóstico y el tratamiento de los trastornos mentales. La colaboración entre científicos de datos, expertos en salud mental y profesionales de diversas disciplinas será fundamental para asegurar que estos avances se traduzcan en una mejora concreta en la calidad de vida de las personas en todo el mundo.

#### Conflictos de intereses

Los autores declaran que no existen conflictos de intereses.

## Referencias

1. Abrams Z. AI is changing every aspect of psychology. Here's what to watch for. Monitor APA. 2023; 54(5):46-53. Available from: <https://www.apa.org/monitor/2023/07/psychology-embracing-ai>
2. Adlung L, Cohen Y, Mor U, Elinav E. Machine learning in clinical decision making. Med. 2021;2(6):642-65. DOI: 10.1016/j.medj.2021.04.006
3. American Psychological Association. APA diccionario conciso de psicología. México: El Manual Moderno; 2010.
4. Ashrafian H, Darzi A. Transforming health policy through machine learning. PLoS Med. 2018;15(11):e1002692. DOI: 10.1371/journal.pmed.1002692
5. Bedi G, Carrillo F, Cecchi GA, Fernández Slezak D, Sigman M, Mota NB, et al. Automated analysis of free speech predicts psychosis onset in high-risk youths. NPJ Schizophr. 2015;1:15030. PMID: 27336038 DOI: 10.1038/npjschz.2015.30
6. Bishop CM. Pattern recognition and machine learning. Nueva York: Springer; 2006.
7. Breiman L. Random forests. Mach Learn. 2001;45:5-32. DOI: 10.1023/A:1010933404324
8. Buonocore M, Bechi M, Uberti P, Spangaro M, Cocchi F, Guglielmino C, et al. Cognitive reserve profiles in chronic schizophrenia: Effects on theory of mind performance and improvement after training. J Int Neuropsychol Soc. 2018;24(6):563-71. PMID: 29557317 DOI: 10.1017/S1355617718000012.
9. Cacheda F, Fernandez D, Novoa FJ, Carneiro V. Early detection of depression: Social network analysis and random forest techniques. J Med Internet Res. 2019;21(6):e12554. PMID: 31199323 DOI: 10.2196/12554
10. Chattopadhyay S, Kaur P, Rabhi F, Acharya UR. Neural network approaches to grade adult depression. J Med Syst. 2012;36(5):2803-15. PMID: 21833604 DOI: 10.1007/s10916-011-9759-1
11. Chekroud AM, Zotti RJ, Shehzad Z, Gueorguieva R, Johnson MK, Trivedi MH, et al. Cross-trial prediction of treatment outcome in depression: a machine learning approach. Lancet Psychiatry. 2016;3(3):243-50. PMID: 26803397 DOI: 10.1016/S2215-0366(15)00471-X
12. Cortes C, Vapnik V. Support-vector networks. Mach Learn. 1995;20:273-97. DOI: 10.1007/BF00994018
13. Čosić K, Popović S, Šarlija M, Kesedžić I, Jovanović T. Artificial intelligence in prediction of mental health disorders induced by the COVID-19 pandemic among health care workers. Croat Med J. 2020;61(3):279-88. PMID: 32643346 DOI: 10.3325/cmj.2020.61.279
14. Dwyer DB, Falkai P, Koutsouleris N. Machine Learning Approaches for Clinical Psychology and Psychiatry. Annu Rev Clin Psychol. 2018;14:91-118. PMID: 29401044 DOI: 10.1146/annurev-clinpsy-032816-045037
15. Garriga R, Mas J, Abraha S, Nolan J, Harrison O, Tadros G, Matic A. Machine learning model to predict mental health crises from electronic health records. Nat Med. 2022;28(6):1240-8. PMID: 35577964 DOI: 10.1038/s41591-022-01811-5
16. Giordano C, Brennan M, Mohamed B, Rashidi P, Modave F, Tighe P. Assessing artificial intelligence

- for clinical decision-making. *Front Digit Health.* 2021;3:645232. PMID: 34713115 DOI: 10.3389/fdgh.2021.645232
17. Gkotsis G, Oellrich A, Velupillai S, Liakata M, Hubbard TJP, Dobson RJB, Dutta R. Characterisation of mental health conditions in social media using Informed Deep Learning. *Sci Rep.* 2017;7:45141. PMID: 28327593 DOI: 10.1038/srep45141
  18. Goodfellow I, Bengio Y, Courville A. Deep learning. Cambridge: MIT Press; 2016.
  19. Hastie T, Tibshirani R, Friedman J. The elements of statistical learning: Data mining, inference, and prediction. 2nd ed. Nueva York: Springer Science & Business Media; 2009.
  20. Haufe S, Meinecke F, Görgen K, Dähne S, Haynes JD, Blankertz B, Bießmann F. On the interpretation of weight vectors of linear models in multivariate neuroimaging. *Neuroimage.* 2014;87:96-110. DOI: 10.1016/j.neuroimage.2013.10.067
  21. Haupt CE, Marks M. AI-generated medical advice—GPT and beyond. *JAMA.* 2023;329(16):1349-50. DOI: 10.1001/jama.2023.5321
  22. Iyortsuun NK, Kim SH, Jhon M, Yang HJ, Pant S. A review of machine learning and deep learning approaches on mental health diagnosis. *Healthcare (Basel).* 2023;11(3):285. PMID: 36766860 DOI: 10.3390/healthcare11030285
  23. Kim WP, Kim HJ, Pack SP, Lim JH, Cho CH, Lee HJ. Machine learning-based prediction of attention-deficit/hyperactivity disorder and sleep problems with wearable data in children. *JAMA Netw Open.* 2023;6(3):e233502. PMID: 36930149 DOI: 10.1001/jamanetworkopen.2023.3502
  24. Krogh A. What are artificial neural networks? *Nat Biotechnol.* 2008;26(2):195-7. PMID: 18259176 DOI: 10.1038/nbt1386
  25. Krumholz HM. Big data and new knowledge in medicine: The thinking, training, and tools needed for a learning health system. *Health Aff (Millwood).* 2014;33(7):1163-70. PMID: 25006142 DOI: 10.1377/hlthaff.2014.0053.
  26. Kuhn M, Johnson K. Applied predictive modeling. Nueva York: Springer; 2013.
  27. LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature.* 2015;521(7553):436-44. PMID: 26017442 DOI: 10.1038/nature14539
  28. Lim JS, Yang CM, Baek JW, Lee SY, Kim BN. Prediction models for suicide attempts among adolescents using machine learning techniques. *Clin Psychopharmacol Neurosci.* 2022;20(4):609-20. PMID: 36263637 DOI: 10.9758/cpn.2022.20.4.609
  29. López Steinmetz LC, Sison M, Zhumagambetov R, Haufe S, Godoy JC. Machine learning to predict depression in college students during the Argentinean quarantine for the COVID-19 pandemic. En: XIX Encuentro Nacional y VIII Encuentro Internacional de la Asociación Argentina de Ciencias del Comportamiento (AACC). Asociación Argentina de Ciencias del Comportamiento, Ciudad Autónoma de Buenos Aires, Argentina, 23-25 agosto, 2023.
  30. Mariñelarena-Dondena L, Ferretti E, Maragoudakis M, Sapino Me, Errecalede ML. Predicting depression: A comparative study of machine learning approaches based on language usage. *Cuad Neuropsicol.* 2017;11 (3):42-54. Available from: <https://www.redalyc.org/journal/4396/439656187002/html/>
  31. Murphy KP. Machine learning: A probabilistic perspective. Cambridge: MIT Press; 2012.
  32. Nogay HS, Adeli H. Machine learning (ML) for the diagnosis of autism spectrum disorder (ASD) using brain imaging. *Rev Neurosci.* 2020; /j/revneuro. ahead-of-print/revneuro-2020-0043/revneuro-2020-0043.xml. PMID: 32866134 DOI: 10.1515/revneuro-2020-0043
  33. Rajkomar A, Hardt M, Howell MD, Corrado G, Chin MH. Ensuring fairness in machine learning to advance health equity. *Ann Intern Med.* 2018;169(12):866-72. PMID: 30508424 DOI: 10.7326/M18-1990
  34. Ray A, Bhardwaj A, Malik YK, Singh S, Gupta R. Artificial intelligence and Psychiatry: An overview. *Asian J Psychiatr.* 2022;70:103021. PMID: 35219978 DOI: 10.1016/j.ajp.2022.103021.
  35. Shatte ABR, Hutchinson DM, Teague SJ. Machine learning in mental health: A scoping review of methods and applications. *Psychol Med.* 2019; 49(9):1426-48. PMID: 30744717 DOI: 10.1017/S0033291719000151
  36. Terra M, Baklola M, Ali S, El-Bastawisy K. Opportunities, applications, challenges and ethical implications of artificial intelligence in psychiatry: A narrative review. *Egypt J Neurol Psychiatry Neurosurg.* 2023;59:80. DOI: 10.1186/s41983-023-00681-z
  37. van Heerden AC, Pozuelo JR, Kohrt BA. Global mental health services and the impact of artificial intelligence-powered large language models. *JAMA Psychiatry.* 2023;80(7):662-4. PMID: 37195694 DOI: 10.1001/jamapsychiatry.2023.1253
  38. World Health Organization [internet]. Mental disorders. 8 junio 2022. [Consultado 30/08/2023]. Available from: <https://www.who.int/news-room/fact-sheets/detail/mental-disorders>