

# Inteligencia artificial en psiquiatría: innovaciones, desafíos y futuro del diagnóstico y tratamiento. Revisión bibliográfica

## Artificial intelligence in psychiatry: innovations, challenges and future diagnosis and treatment. Bibliographic review

Leynis Carolina Ocando Parra, MD<sup>1,2\*</sup> <https://orcid.org/0000-0001-6473-3746>

<sup>1</sup>Asociación Chilena de Seguridad.

<sup>2</sup>Diplomado en Salud Ocupacional, Diplomado en Manejo de Situaciones Críticas en Salud Mental. Universidad de Los Andes. Chile.

**\*Autor de correspondencia:** Leynis Carolina Ocando Parra, MD. Asociación Chilena de Seguridad. Diplomado en Salud Ocupacional. Diplomado en Manejo de Situaciones Críticas en Salud Mental. Universidad de Los Andes. Chile. [leynisocando@gmail.com](mailto:leynisocando@gmail.com)

Received: 10/20/2024 Accepted: 01/19/2025 Published: 02/12/2025 DOI: <http://doi.org/10.5281/zenodo.14876759>

### Resumen

La inteligencia artificial (IA) se trata de un recurso tecnológico y revolucionario que se encuentra transformando la psiquiatría mediante el desarrollo de herramientas avanzadas que optimizan tanto el diagnóstico como el tratamiento de los trastornos mentales. Tecnologías como el aprendizaje automático (AA) y el procesamiento de lenguaje natural (PLN) permiten analizar patrones complejos en neuroimágenes, datos clínicos y lenguaje, facilitando diagnósticos más tempranos y personalizados. No obstante, la adopción de estas tecnologías enfrenta desafíos considerables, entre ellos las preocupaciones éticas relacionadas con la privacidad de los datos, los sesgos inherentes en los modelos y la falta de estándares que aseguren la reproducibilidad de los resultados. Basado en una revisión bibliográfica sistematizada de estudios recientes, se evaluaron las tecnologías de IA, incluyendo algoritmos de AA, PLN y análisis de neuroimágenes,

con el objetivo de identificar su eficacia, limitaciones y posibilidades futuras. La evidencia indica que las herramientas predictivas logran tasas de precisión superiores al 90% en la detección de enfermedades como el Alzheimer y la depresión mayor, mientras que, sistemas como chatbots terapéuticos ofrecen apoyo continuo, anónimo y accesible a los pacientes. Aunque prometedora, la IA enfrenta barreras éticas, técnicas y sociales. Sin embargo, posee una potencial capacidad para atender la creciente demanda de servicios psiquiátricos, especialmente en regiones con acceso limitado a especialistas. En el futuro, estas tecnologías podrían evolucionar hacia sistemas más integrados y responsables, capaces de combinar avances tecnológicos con principios humanos como la empatía, promoviendo diagnósticos equitativos y tratamientos adaptados a las necesidades individuales.

**Palabras clave:** inteligencia artificial, psiquiatría, diagnósticos personalizados, tratamiento, ética, privacidad.

**A**rtificial intelligence (AI) is a revolutionary technological resource that is transforming psychiatry through the development of advanced tools that optimize both the diagnosis and treatment of mental disorders. Technologies such as machine learning (ML) and natural language processing (NLP) allow the analysis of complex patterns in neuroimaging, clinical data, and language, facilitating earlier and more personalized diagnoses. However, the adoption of these technologies faces considerable challenges, including ethical concerns related to data privacy, the systems incorporated in the models, and the lack of standards that ensure the reproducibility of the results. Based on a systematic literature review of recent studies, AI technologies, including ML, NLP, and neuroimaging analysis algorithms, are evaluated with the aim of identifying their effectiveness, limitations, and future possibilities. Evidence indicates that predictive tools achieve accuracy rates of over 90% in detecting diseases such as Alzheimer's and major depression, while systems such as therapeutic chatbots offer continuous, anonymous and accessible support to patients. Although promising, AI faces ethical, technical and social barriers. However, it has the potential to meet the growing demand for psychiatric services, especially in regions with limited access to specialists. In the future, these technologies could evolve into more integrated and accountable systems, capable of combining technological advances with human principles such as empathy, promoting equitable diagnoses and treatments tailored to individual needs.

**Keywords:** artificial intelligence, psychiatry, personalized diagnoses, treatment, ethics, privacy.

**L**a inteligencia artificial (IA) ha emergido como una herramienta revolucionaria en el ámbito de la salud, facilitando avances importantes en el diagnóstico y tratamiento de diversas condiciones médicas<sup>1</sup>. Si bien la IA ya ha mostrado su efectividad en especialidades como oncología y radiología, su implementación en psiquiatría está aún en desarrollo<sup>2,3</sup>. La complejidad de los trastornos mentales, caracterizados por su heterogeneidad sintomática y la influencia de factores subjetivos, plantea retos únicos para la aplicación de algoritmos de IA<sup>4</sup>. No obstante, el potencial de estas tecnologías para transformar la psiquiatría es inmenso, ya que permiten analizar grandes volúmenes de datos y descubrir patrones que podrían pasar desapercibidos para el ojo humano<sup>5</sup>. En este contexto, explorar las capacidades de la IA en el diagnóstico y tratamiento psiquiátrico podría optimizar el manejo de estos trastornos, abordando el creciente número de casos y la escasez de profesionales de salud mental<sup>6</sup>.

Así, la capacidad de la IA para procesar grandes volúmenes de datos permite identificar patrones en imágenes cerebrales y registros clínicos, lo cual facilita diagnósticos tempranos y más precisos. Además, mediante el procesamiento de lenguaje natural (PLN), la IA puede analizar registros médicos y redes sociales para detectar signos de condiciones como la depresión o la ideación suicida, aportando una nueva dimensión al diagnóstico preventivo en salud mental<sup>7,8</sup>. En cuanto al tratamiento, la IA ofrece aplicaciones terapéuticas como asistentes virtuales que complementan la terapia tradicional, proporcionando apoyo y seguimiento continuo a los pacientes<sup>1,9</sup>. Esto no solo mejora la accesibilidad de la atención psiquiátrica, sino que también optimiza los recursos en salud mental, liberando tiempo para que los profesionales puedan concentrarse en la relación terapéutica<sup>10</sup>. La personalización de tratamientos mediante algoritmos de IA también se vislumbra como un avance determinante, permitiendo adaptar las intervenciones a las características específicas de cada paciente, aumentando la eficacia y reduciendo los riesgos de tratamientos inadecuados<sup>11</sup>.

Sin embargo, el uso de IA en psiquiatría enfrenta desafíos significativos, principalmente en términos de privacidad de los datos, ética y transparencia de los algoritmos<sup>12</sup>. La naturaleza sensible de la información en salud mental exige estrictas medidas de protección de datos, y la complejidad de los modelos de IA plantea interrogantes sobre su interpretabilidad y riesgo de sesgos. Estos factores resaltan la importancia de desarrollar marcos éticos y normativos sólidos para garantizar un uso seguro y justo de la IA<sup>13</sup>. Esta revisión busca explorar la aplicabilidad de la IA en el diagnóstico y tratamiento

psiquiátrico, evaluando sus limitaciones actuales y proyectando su potencial futuro para mejorar la atención en salud mental.

Los datos de cada estudio se resumieron y presentaron en tablas. La calidad de la evidencia y la fuerza de recomendación de cada estudio se evaluaron utilizando el sistema GRADE<sup>15</sup>.

## Methodology

**S**e realizó una revisión narrativa de la literatura mediante una búsqueda sistemática y estructurada de estudios, basado en el método PRISMA<sup>14</sup>. La investigación se orientó en responder la pregunta: ¿Cuál es la aplicabilidad de la inteligencia artificial en el diagnóstico y tratamiento de trastornos psiquiátricos? Para abordarla, se establecieron criterios de selección específicos, entre los que se encontraba: la inclusión de estudios publicados en los últimos cinco años y disponibles en inglés o español; estudios observacionales transversales, longitudinales, de cohorte, revisiones sistemáticas y metaanálisis, en los que se evaluaba la aplicabilidad de la IA en situaciones relacionadas con la salud mental. Por otro lado, los criterios de exclusión contemplaron la exclusión de estudios que no aplicaran IA de forma directa en el diagnóstico o tratamiento psiquiátrico, así como artículos centrados en otras especialidades médicas o en psicología general sin una aplicación específica en psiquiatría. También se descartaron publicaciones que no presentaran resultados empíricos o análisis de impacto relevante en la práctica psiquiátrica y artículos de opinión o publicaciones sin revisión por pares. Las variables evaluadas abarcaron la Innovaciones Tecnológicas, Eficacia Diagnóstica, Tratamiento, Desafíos Éticos y Legales, Perspectivas Futuras y Adopción Clínica.

La estrategia de búsqueda bibliográfica se realizó utilizando los términos: ((“Artificial Intelligence” AND “Psychiatry”) OR (“AI” AND “Mental Health”)); (((“AI-based Diagnosis” OR “AI Diagnosis” OR “Diagnosis with AI”); (“AI-based Treatment” OR “AI in Treatment”)) AND (“Mental Disorders” OR “Mental Health Disorders”)); ((“AI Innovations” OR “Innovations in Artificial Intelligence” OR “AI Advancements”) AND (“Psychiatric Treatment” OR “Treatments in Psychiatry”)); revisándose las bases de datos PubMed, ScienceDirect, Taylor & Francis y Cochrane Library. La búsqueda de artículos tuvo una duración de 3 meses, desde octubre a diciembre de 2024. El proceso de selección comenzó con la fase de identificación, donde se localizaron más de 7 mil registros en las bases de datos electrónicas, que posterior a la aplicación de los criterios de selección, quedaron reducidos a 68 estudios, los cuales fueron sometidos a una evaluación más detallada. Durante la fase de elegibilidad, se evaluaron los textos completos y, finalmente, 19 estudios fueron incluidos para el análisis descriptivo.

## INTELIGENCIA ARTIFICIAL EN PSIQUIATRÍA

La IA se trata una herramienta que busca crear sistemas capaces de ejecutar tareas propias de la inteligencia humana, como el aprendizaje, el procesamiento del lenguaje, el reconocimiento de patrones y la toma de decisiones. Dicha capacidad para automatizar procesos complejos, abre nuevas posibilidades en distintos ámbitos, incluyendo la psiquiatría, donde se han evaluado diversas aplicaciones de sus subconjuntos para mejorar la práctica clínica<sup>16</sup>.

### Aprendizaje automático o Machine learning

El aprendizaje automático (AA) o machine learning es una de las aplicaciones más utilizadas de la IA en el ámbito de la salud, y en psiquiatría está mostrando un importante potencial para mejorar el diagnóstico y tratamiento de los trastornos mentales<sup>12</sup>. A diferencia de los enfoques estadísticos tradicionales, el AA se caracteriza por ser más generador de hipótesis que impulsado por ellas, lo cual permite explorar patrones en grandes volúmenes de datos sin las limitaciones de supuestos estrictos<sup>17</sup>. Los algoritmos de AA tienen la capacidad de aprender de los datos históricos y hacer predicciones sobre respuestas a tratamientos o clasificar a los pacientes dentro de ciertos espectros de desórdenes mentales, basándose en variables como el historial médico y otros factores relevantes<sup>4</sup>. En este sentido, la Sociedad Internacional para el Trastorno Bipolar ha desarrollado directrices que describen los pasos para usar datos de diferentes fuentes para crear calculadoras de riesgo, demostrando el valor práctico de AA en el campo<sup>18</sup>.

Además, el AA en psiquiatría se centra en la identificación de patrones y la predicción de resultados futuros, como la respuesta de un paciente con depresión a un tratamiento específico o su riesgo de recaída<sup>19</sup>. Estos modelos de AA, adaptados a la complejidad y variabilidad de los datos de salud mental, también facilitan la categorización de pacientes en distintos espectros de trastornos, ayudando a los clínicos a realizar diagnósticos más precisos y personalizados. Diversos estudios y guías metodológicas han sido publicados para apoyar la aplicación de AA en psiquiatría, proporcionando recomendaciones sobre cómo evaluar el rendimiento de estos modelos y su adecuación a los datos de entrada, garantizando así su aplicabilidad y fiabilidad en la práctica clínica<sup>20,21</sup>.

### Procesamiento de lenguaje natural

El procesamiento de lenguaje natural (PLN) o natural language processing es un subcampo de la IA centrado en la interacción entre las computadoras y el lenguaje humano, permitiendo que los sistemas comprendan, in-

terpreten y generen texto de manera significativa<sup>22</sup>. En psiquiatría, el PLN tiene un potencial importante, ya que facilita el análisis de lenguaje y discurso, dos fuentes clave de información en el diagnóstico y tratamiento de trastornos mentales<sup>23</sup>. Mediante técnicas de reconocimiento de voz y análisis semántico y de sentimiento, el PLN convierte texto no estructurado en datos estructurados, lo que permite un análisis más profundo y eficiente<sup>24</sup>. Estas técnicas pueden detectar signos de condiciones de salud mental a partir del lenguaje utilizado por los pacientes, identificando posibles síntomas de trastornos como la depresión o la ideación suicida<sup>25</sup>.

El PLN también se ha utilizado para analizar publicaciones en redes sociales, identificando patrones de comportamiento que podrían indicar problemas de salud mental<sup>26</sup>. En entornos clínicos, el PLN se aplica en el procesamiento de registros médicos electrónicos para automatizar la revisión de historiales, agrupar a los pacientes en fenotipos específicos, y prever riesgos, como el de readmisión temprana o intentos de suicidio<sup>22</sup>. Además, plataformas como el Clinical Record Interactive Search integran PLN para mejorar la investigación en salud mental, haciendo posible una detección temprana y más precisa de factores de riesgo en la población psiquiátrica<sup>27</sup>. Estos avances en PLN están permitiendo a los profesionales de la salud acceder a información detallada y procesable, lo que optimiza el proceso de toma de decisiones y mejora el cuidado del paciente en psiquiatría<sup>12</sup>.

### **Redes neuronales, *deep learning* y *reinforcement learning***

En psiquiatría, las redes neuronales y el *deep learning* representan técnicas avanzadas de aprendizaje automático que simulan el funcionamiento del cerebro humano, permitiendo el procesamiento de grandes volúmenes de datos complejos, como imágenes cerebrales<sup>28</sup>. Estas herramientas identifican patrones en los datos que podrían pasar desapercibidos para el ojo humano, ayudando a los profesionales a entender mejor los tras-

tornos mentales y a realizar diagnósticos más precisos. Gracias a la capacidad de estas redes de extraer información valiosa de datos no estructurados, el *deep learning* facilita el análisis de variables relacionadas con la estructura y funcionamiento del cerebro en condiciones psiquiátricas específicas, apoyando la investigación en neuroimagen y la identificación de biomarcadores<sup>29</sup>.

Por otro lado, el *reinforcement learning* y los modelos de lenguaje extensivo, como GPT y LLaMA, ofrecen aplicaciones innovadoras en la personalización de tratamientos y en el apoyo terapéutico. El *reinforcement learning* permite a los sistemas aprender estrategias de tratamiento ajustadas a cada paciente mediante retroalimentación continua, optimizando así los planes de atención en función de los resultados obtenidos. Los modelos de lenguaje, en tanto, son capaces de generar texto similar al humano, lo cual es útil para desarrollar agentes conversacionales o chatbots en el ámbito de la salud mental<sup>30</sup>. Estos agentes proporcionan soporte inmediato, anónimo y sin juicio, lo cual es especialmente valioso para quienes pueden sentir reticencia a acudir a terapia convencional. Sin embargo, el uso de estos modelos en psiquiatría plantea desafíos éticos y de privacidad que deben ser abordados mediante marcos legales sólidos y medidas de protección de datos rigurosas, dada la sensibilidad de la información en el contexto de la salud mental<sup>12</sup>.

### **Aplicaciones diagnósticas de la IA en Psiquiatría**

La IA está revolucionando el diagnóstico de trastornos psiquiátricos al aprovechar algoritmos avanzados de aprendizaje automático y técnicas PLN. Estas herramientas permiten analizar datos complejos, como neuroimágenes, registros de lenguaje y datos conductuales, para identificar patrones que a menudo pasan desapercibidos mediante métodos tradicionales (Tabla 1). Además, la IA facilita la integración de diversas fuentes de información, como registros electrónicos de salud y datos genéticos, optimizando la personalización de los diagnósticos y las intervenciones clínicas<sup>4,12</sup>.

Tabla 1. Aplicaciones diagnósticas de la IA en Psiquiatría.

Autor (Año)	Estrategia/Diseño	Hallazgos principales
Shin et al. (2023)	Uso de exosomas plasmáticos como biomarcadores para el diagnóstico de TDM, combinando SERS con aprendizaje profundo; 28,000 señales procesadas y validadas con 70 muestras independientes.	AUC: 0.939, sensibilidad: 91.4%, especificidad: 88.6%. Los puntajes diagnósticos correlacionaron con el grado de depresión, destacando el potencial de los exosomas como biomarcadores precisos.
Noda et al. (2024)	Datos de EEG en reposo y TMS-EEG para diagnosticar depresión; análisis de 60 pacientes depresivos y 60 controles con nueve modelos de IA combinando modalidades de datos.	Mejor modelo con análisis discriminante lineal, AUC promedio: 0.922. Los índices neurofisiológicos derivados de TMS-EEG permitieron alta precisión diagnóstica.
Allesøe et al. (2022)	Aprendizaje profundo no supervisado para estratificar pacientes con TDM y EZ mediante el caso-cohorte iPSYCH2012, integrando datos clínicos, genéticos y demográficos.	Clusters de TDM: AUC de 0.54-0.80; EZ: AUC de 0.71-0.86. Estratificación útil para subclasificar y mejorar diagnósticos.
Colombo et al. (2022)	Revisión sistemática y meta-análisis conforme a PRISMA sobre clasificación del trastorno bipolar con 81 estudios, incluyendo 11,336 participantes.	Precisión global: 0.77. Relación inversa entre tamaño muestral y precisión, con sesgo de publicación evidente.
Chan et al., (2023)	Análisis de narrativas autobiográficas mediante PLN en 167 pacientes con EZ y 90 controles sanos, explorando características lingüísticas relacionadas con el «yo».	Clasificador con AUC: 0.80. Detección de aspectos fenomenológicos de EZ sin intervención explícita.
Fu et al. (2021)	Desarrollo de Sch-net, una RNC con bloques convolucionales para detectar habla esquizofrénica en 28 pacientes y 28 controles sanos.	Precisión: 97.68%. Validación en base LANNA: 99.52%. Herramienta confiable para diagnóstico de EZ y trastornos del lenguaje.
Huang et al. (2022)	Uso de videos faciales procesados mediante ResNet18_3D para detectar EZ en 125 pacientes y 75 controles durante tareas de estimulación emocional.	Precisión: 89%, AUC: 0.9397. Los estímulos emocionales ordenados mostraron mejor rendimiento.
Doborjeh et al. (2021)	Modelo RNE para predecir deterioro cognitivo leve (MCI) y demencia basado en neuroimágenes longitudinales de 175 adultos mayores durante 6 años.	Precisión: 95% (MCI), 91% (demencia). Visualización de cambios dinámicos en la intensidad de la sustancia blanca y volumen cerebral.
James et al. (2021)	Algoritmos de AA para predecir demencia en 15,307 participantes, integrando 258 variables clínicas y demográficas.	Precisión: 92%, AUC: 0.92. Solo seis variables necesarias para alta precisión diagnóstica.
Park et al. (2020)	Datos administrativos de salud para predecir EA en 40,736 personas mayores usando AA.	AUC: 0.775-0.725 (1-4 años). Importancia de hemoglobina y proteínas urinarias como predictores.
You et al. (2022)	Modelo predictivo basado en UK Biobank con 425,159 participantes, integrando 366 variables clínicas y genéticas.	AUC: 0.848 (demencia), 0.862 (EA). Superó modelos tradicionales, aunque requiere validación externa.
Salehi et al. (2020)	RNC para detección temprana de EA usando imágenes MRI de ADNI.	Precisión: 99%. Superioridad del aprendizaje profundo sobre técnicas tradicionales de AA.
Wei et al. (2023)	Meta-análisis sobre AA aplicado a seguimiento ocular en EA, analizando 24 estudios.	Precisión global: 81%. Mejor desempeño en preescolares (88%) que en escolares o adultos.
Afshar et al. (2022)	PLN para identificar uso indebido de sustancias en notas clínicas de EHR con validaciones internas y externas.	AUROC promedio: 0.97. Validación externa sólida para alcohol (0.88) y opioides (0.94).

AA: Aprendizaje automático. AUC: Área bajo la curva ROC. EA: Enfermedad de Alzheimer. EEG: Electroencefalografía. EZ: Esquizofrenia. HCE: Historias clínicas electrónicas. IA: Inteligencia artificial. MRI: Imágenes de resonancia magnética. PLN: Procesamiento de lenguaje natural. RNC: Red neuronal convolucional. RNE: Redes neuronales espiking. SERS: Espectroscopia Raman mejorada en superficie. TDM: Trastorno depresivo mayor. TEA: Trastorno del espectro autista. TMS-EEG: Estimulación magnética transcraneal combinada con EEG. UKB: UK Biobank.



En el ámbito del diagnóstico del trastorno depresivo mayor, Shin et al. (2023) desarrollaron un modelo basado en exosomas plasmáticos y espectroscopia Raman mejorada en superficie (SERS). Este sistema logró una precisión sobresaliente, con un área bajo la curva (AUC) de 0.939, una sensibilidad del 91.4% y una especificidad del 88.6%, demostrando la utilidad de los exosomas como biomarcadores innovadores<sup>31</sup>. Simultáneamente, Noda et al. (2024) emplearon datos de electroencefalografía (EEG) en estado de reposo y estimulaciones transcraneales (TMS-EEG) para alcanzar un AUC promedio de 0.922, destacando la capacidad de los índices neurofisiológicos en la discriminación de pacientes con depresión y controles sanos<sup>32</sup>. Por su parte, Allesøe et al. (2022) aplicaron aprendizaje profundo no supervisado para identificar subtipos de depresión y esquizofrenia mediante clusters clínicos y genéticos, alcanzando una capacidad predictiva de hasta 0.81 en la clasificación de casos frente a controles<sup>33</sup>.

Así, la IA también está demostrando una alta eficacia en el diagnóstico de esquizofrenia, según lo publicado por distintos autores. Al respecto, Chan et al. (2023) emplearon PLN para analizar narrativas autobiográficas de pacientes, identificando patrones lingüísticos relacionados con la experiencia del «yo» que fueron altamente significativos en pacientes con esquizofrenia. Este enfoque alcanzó un AUC de 0.80, evidenciando cómo el lenguaje puede reflejar síntomas clínicos subyacentes<sup>34</sup>. Paralelamente, Fu et al. (2021) desarrollaron la red neuronal Sch-net para detectar patrones de habla esquizofrénica, logrando una precisión del 97.68%<sup>35</sup>, mientras que, Huang et al. (2022) emplearon videos faciales y aprendizaje profundo, obteniendo una precisión del 89% y un AUC de 0.9397 al identificar cambios emocionales relacionados con la enfermedad<sup>36</sup>.

En el diagnóstico de demencia y Alzheimer, la evidencia señala que la IA representa una herramienta con potencial clínico. En este sentido, Doborjeh et al. (2021) aplicaron redes neuronales espiking para analizar datos longitudinales de resonancia magnética (MRI), logrando predicciones precisas del deterioro cognitivo leve y demencia con un 95% y 91% de precisión, respectivamente<sup>37</sup>. Asimismo, James et al. (2021) utilizaron modelos de árboles potenciados por gradiente, alcanzando un AUC de 0.92 para predecir la demencia en dos años utilizando solo seis variables clave<sup>38</sup>. Por otro lado, Park et al.

(2020) entrenaron modelos de aprendizaje automático basados en datos administrativos de salud, logrando un desempeño razonable con AUCs entre 0.775 y 0.725 para predicciones a 1-4 años (20). Finalmente, You et al. (2022)<sup>39</sup> y Salehi et al. (2020)<sup>40</sup> demostraron que los modelos basados en neuroimágenes y aprendizaje profundo pueden superar los enfoques tradicionales, alcanzando precisiones del 99% para la clasificación de Alzheimer.

En el diagnóstico del Trastorno del Espectro Autista, Wei et al. (2023) realizaron un meta-análisis que demostró la eficacia de los algoritmos de aprendizaje automático basados en datos de seguimiento ocular, con una precisión agrupada del 81%. Este método fue especialmente efectivo en niños en edad preescolar, donde la precisión alcanzó el 88%, resaltando el potencial de estas herramientas en etapas tempranas del desarrollo<sup>41</sup>. Por otro lado, Afshar et al. (2022) aplicaron PLN para analizar notas clínicas hospitalarias y detectar patrones de uso indebido de sustancias, logrando un AUC promedio de 0.97. Este método demostró alta confiabilidad para identificar conductas aberrantes de consumo en diversos contextos hospitalarios<sup>42</sup>.

De esta forma, la IA está redefiniendo la práctica psiquiátrica al integrar múltiples dominios de datos y proporcionar herramientas diagnósticas más precisas y eficaces. Desde biomarcadores innovadores hasta análisis de lenguaje y neuroimágenes, estas tecnologías están mejorando la precisión diagnóstica, personalizando las intervenciones y optimizando los recursos clínicos. Sin embargo, aún se requieren estudios adicionales para validar estos métodos y garantizar su implementación ética y equitativa en la práctica clínica global.

### **Aplicaciones terapéuticas de la IA en Psiquiatría**

En el ámbito terapéutico, la IA ha transformando el panorama terapéutico en psiquiatría al ofrecer herramientas que permiten optimizar los tratamientos, personalizar las intervenciones y mejorar los resultados clínicos (Tabla 2). A través del análisis de datos complejos, como biomarcadores, neuroimágenes y registros clínicos, la IA facilita la predicción de respuestas terapéuticas en pacientes individuales, evitando regímenes prolongados con tratamientos ineficaces y promoviendo decisiones más informadas.

Tabla 2. Aplicaciones terapéuticas de la IA en Psiquiatría		
Autor (Año)	Metodología	Hallazgos principales
Gomeni et al. (2023)	Ensayo clínico aleatorizado, doble ciego, controlado con placebo, evaluando la paroxetina CR en dos dosis. Uso de ponderación por propensión para modelar efectos del placebo con IA.	La ponderación por propensión duplicó la estimación del efecto del tratamiento en comparación con análisis no ponderados, mejorando la precisión y comparabilidad entre grupos.
Joyce et al. (2021)	Análisis de datos metabolómicos y variantes genéticas (SNPs) en pacientes con TDM, integrando SNPs en modelos de IA para predecir respuesta a combinaciones de antidepresivos.	Integración de SNPs mejoró la precisión (AUC 0.86 vs. 0.85). Esfingomielinas hidroxiladas destacaron como biomarcadores claves en la respuesta terapéutica.
Taliaz et al. (2021)	Uso de aprendizaje automático en datos de STAR*D para predecir respuestas a antidepresivos, combinando factores genéticos, clínicos y demográficos.	Precisión balanceada del 72.3% (validación) y 70.1% (prueba). Resultados consistentes en datos externos, optimizando la selección de antidepresivos.
Sadeh-Sharvit et al. (2023)	Ensayo controlado aleatorizado para evaluar una plataforma de IA en terapia cognitivo-conductual, analizando adherencia, síntomas y progreso clínico.	Incremento del 67% en adherencia y reducción del 34% en síntomas depresivos, con mayor rapidez en reportes clínicos y mejores resultados en pacientes.
Wang et al. (2022)	Análisis de MRI y PRS en pacientes con esquizofrenia, empleando clasificadores basados en IA para predecir respuesta al tratamiento antipsicótico.	Precisión del 86% con contribuciones destacadas de Volumen de Materia Gris, Amplitud de Fluctuaciones de Baja Frecuencia y PRS. Resultados evidenciaron valor agregado al combinar estas características.
AUC: Área bajo la curva ROC. IA: Inteligencia artificial. MRI: Imágenes de resonancia magnética. PRS: Puntaje de Riesgo Poligénico. SNPs: Polimorfismos de Nucleótido Único. TDM: Trastorno depresivo mayor.		

En este sentido, Gomeni et al. (2023) demostraron el impacto de la IA en la evaluación de la eficacia terapéutica en un ensayo clínico aleatorizado y controlado con placebo para el tratamiento con paroxetina. Al emplear un modelo basado en ponderación por propensión, se logró estimar con mayor precisión el efecto del tratamiento, duplicando la magnitud del efecto observado en comparación con métodos tradicionales<sup>43</sup>. Esta metodología abordó eficazmente las variaciones heterogéneas y no controladas del placebo, destacando su capacidad para mejorar la comparabilidad entre grupos de estudio.

En un enfoque similar, Joyce et al. (2021) evaluaron la respuesta a terapias combinadas en pacientes con trastorno depresivo mayor mediante modelos de aprendizaje automático integrando metabolómica y variantes genéticas funcionales. Los modelos alcanzaron una precisión del 77.5% (AUC: 0.86) al predecir resultados terapéuticos, destacándose las esfingomielinas hidroxiladas como biomarcadores importantes<sup>44</sup>. Por su parte, Taliaz et al. (2021) desarrollaron un algoritmo de AA utilizando datos del estudio STAR\*D para predecir la respuesta individual a tres antidepresivos. El modelo, validado internamente y en un conjunto externo, alcanzó precisiones balanceadas superiores al 70%, demostrando la viabilidad de aplicar grandes bases de datos para optimizar la selección de tratamientos antidepresivos y personalizar las decisiones terapéuticas<sup>45</sup>.

Además, Sadeh-Sharvit et al. (2023) exploraron el uso de una plataforma de IA, Eleos Health, como complemento en terapia cognitivo-conductual ambulatoria para trastornos de ansiedad y depresión. Esta herramienta, que transcribe sesiones, genera retroalimentación basada en evidencia y automatiza notas de progreso, demostró ser efectiva para mejorar la asistencia (+67%) y reducir síntomas de ansiedad (-29%) y depresión (-34%)

en comparación con el tratamiento estándar. Además, la plataforma permitió agilizar procesos administrativos, mostrando su capacidad para integrar tecnología y atención humana en entornos clínicos comunitarios<sup>46</sup>.

La combinación de neuroimágenes y puntajes de riesgo poligénico (PRS) fue explorada por Wang et al. (2022) para predecir la respuesta a antipsicóticos en esquizofrenia. Utilizando modelos basados en XGBoost, se logró una precisión del 86% al integrar medidas de MRI y PRS, identificando categorías como el volumen de materia gris y la amplitud de fluctuaciones de baja frecuencia como predictores cardinales. Este método resalta el valor añadido de combinar múltiples tipos de datos para optimizar el tratamiento en pacientes con esquizofrenia<sup>47</sup>.

Así, la IA está emergiendo como una herramienta práctica en la psiquiatría moderna, ofreciendo soluciones que permiten adaptar las terapias a las necesidades individuales de los pacientes. Desde la predicción de respuestas a tratamientos antidepresivos hasta el apoyo terapéutico en trastornos de ansiedad y la optimización de terapias en esquizofrenia, la IA está transformando las prácticas clínicas al proporcionar modelos más precisos y eficaces. No obstante, es fundamental continuar investigando y validando estas tecnologías para garantizar su implementación ética y eficaz, asegurando que los avances se traduzcan en beneficios tangibles para los pacientes.

### Limitaciones y desafíos de la IA en Psiquiatría

La implementación de la IA en psiquiatría enfrenta importantes barreras, como la dependencia de datos de calidad para entrenar los modelos, lo que puede introducir sesgos y limitar su aplicabilidad fuera de los contextos originales. Problemas como el sobreajuste y subajuste afectan la capacidad de generalización de los modelos,

especialmente cuando las muestras son insuficientes o sesgadas<sup>48-50</sup>. Además, el fenómeno de la «caja negra» dificulta comprender las decisiones tomadas por los modelos de IA, lo que reduce la confianza en su uso en un campo tan delicado como la psiquiatría<sup>51</sup>.

La privacidad y la confidencialidad de los datos son desafíos importantes, ya que los modelos de IA requieren grandes volúmenes de información sensible para su desarrollo. Esto genera preocupaciones sobre la seguridad de los datos de los pacientes y plantea la necesidad de establecer directrices claras para su manejo ético y seguro<sup>52</sup>. Además, la falta de empatía inherente a los sistemas de IA limita su capacidad para proporcionar apoyo emocional adecuado, especialmente en pacientes con antecedentes traumáticos, lo que puede influir en la relación terapéutica<sup>53,54</sup>.

Otro problema es la falta de replicabilidad y reproducibilidad de los modelos de IA, lo que dificulta su adopción en la práctica clínica. La ausencia de estándares unificados para el análisis y presentación de resultados restringe su implementación efectiva<sup>55,56</sup>. Por otro lado, los sistemas multimodales, aunque más completos, enfrentan problemas relacionados con la escalabilidad y complejidad, lo que requiere un equilibrio adecuado entre enfoques simples y complejos para abordar necesidades específicas<sup>57</sup>.

Para abordar estas limitaciones, se recomienda el desarrollo de bases de datos amplias y de alta calidad, junto con marcos de aprendizaje continuo para mejorar la adaptabilidad de los algoritmos<sup>58,59</sup>. La colaboración entre científicos de datos y profesionales de la salud mental puede mejorar la interpretabilidad y confiabilidad de los modelos. Además, la implementación de sistemas de IA explicables permitiría una mayor transparencia en las decisiones, aumentando la confianza de los pacientes y profesionales y facilitando la identificación de sesgos y errores<sup>60,61</sup>. Estos avances contribuirían a transformar la psiquiatría, promoviendo un acceso más equitativo a diagnósticos y tratamientos personalizados.

### Perspectivas futuras

El futuro de la IA en psiquiatría apunta hacia la creación de sistemas más integrados y éticos, capaces de proporcionar una atención más compasiva y personalizada. El concepto de «Sabiduría Artificial» propone desarrollar IA que no solo sea eficiente en el procesamiento de datos, sino también responsable y alineada con valores humanos como la empatía y la justicia. Además, se espera que los avances en el PLN y el aprendizaje profundo permitan una comprensión más profunda de los trastornos mentales y faciliten la implementación de modelos preventivos que identifiquen el riesgo antes de que se manifiesten los síntomas clínicos. Para alcanzar estas metas, es necesario la delimitación de un marco ético y regulatorio sólido que garantice la transparencia y la seguridad en el uso de IA en salud mental<sup>12,22</sup>.

Con la digitalización creciente de los registros de salud, la IA tiene el potencial de revolucionar la psiquiatría al conectar datos biológicos, psicométricos y clínicos en modelos predictivos que puedan aplicarse en la práctica clínica real<sup>62</sup>. El uso de técnicas como el PLN para identificar patrones en el lenguaje, y el empleo de plataformas como ChatGPT para proporcionar apoyo psicoeducativo y seguimiento de síntomas destacan el potencial de estas tecnologías para complementar los servicios de salud mental existentes<sup>63,64</sup>. Finalmente, se deben desarrollar modelos de IA que reduzcan las inequidades sociales y mejoren el acceso a la atención para poblaciones marginadas<sup>65</sup>. La construcción de sistemas médicos basados en big data que combinen indicadores neurobiológicos cuantitativos con datos clínicos podría transformar la detección temprana, la clasificación de enfermedades y la predicción de eficacia terapéutica.

## Conclusiones

La IA ha emergido como una herramienta transformadora en el campo de la psiquiatría, mostrando su capacidad para optimizar diagnósticos y tratamientos en trastornos mentales a través del análisis de grandes volúmenes de datos. Desde algoritmos de AA que predicen respuestas terapéuticas hasta herramientas de PLN que identifican patrones lingüísticos indicativos de patologías, la IA está redefiniendo la práctica clínica en salud mental. Sin embargo, la implementación efectiva de estas tecnologías enfrenta desafíos como la privacidad de datos, los sesgos en los modelos y la falta de estándares unificados, lo que evidencia la necesidad de marcos éticos sólidos y colaboración interdisciplinaria.

La capacidad de la IA para personalizar intervenciones y facilitar diagnósticos tempranos tiene el potencial de abordar la creciente demanda de servicios psiquiátricos, especialmente en regiones con acceso limitado a recursos de salud mental. A través de sistemas como chatbots terapéuticos y modelos predictivos basados en neuroimágenes y biomarcadores, la IA está ampliando la accesibilidad y mejorando la eficiencia en el tratamiento de enfermedades complejas como la esquizofrenia, la depresión y el Alzheimer.

A pesar de sus limitaciones actuales, como la falta de transparencia en los procesos de toma de decisiones y la dependencia de datos de alta calidad, las perspectivas futuras para la IA en psiquiatría son prometedoras. Se espera que tecnologías más integradas, éticas y transparentes impulsen una psiquiatría más precisa, equitativa y personalizada, con aplicaciones preventivas y terapéuticas que transformen el cuidado de la salud mental.



## References

1. Aggarwal A, Tam CC, Wu D, Li X, Qiao S. Artificial Intelligence-Based Chatbots for Promoting Health Behavioral Changes: Systematic Review. *J Med Internet Res*. 2023;25:e40789.
2. Bi WL, Hosny A, Schabath MB, Giger ML, Birkbak NJ, Mehrtash A, et al. Artificial intelligence in cancer imaging: Clinical challenges and applications. *CA Cancer J Clin*. 2019;69(2):127–57.
3. Hosny A, Parmar C, Quackenbush J, Schwartz LH, Aerts HJWL. Artificial intelligence in radiology. *Nat Rev Cancer*. 2018;18(8):500–10.
4. Graham S, Depp C, Lee EE, Nebeker C, Tu X, Kim HC, et al. Artificial Intelligence for Mental Health and Mental Illnesses: an Overview. *Curr Psychiatry Rep*. 2019;21(11):116.
5. Chen Z, Liu X, Yang Q, Wang YJ, Miao K, Gong Z, et al. Evaluation of Risk of Bias in Neuroimaging-Based Artificial Intelligence Models for Psychiatric Diagnosis: A Systematic Review. *JAMA Netw Open*. 2023;6(3):e231671.
6. Rogge E, Briganti G. The Borders of Mental Illness: Investigating Clusters of Diagnostic Criteria in Acute Presentations of Psychiatric Disorders. *Psychiatr Danub*. 2022;34(Suppl 8):220–30.
7. Bzdok D, Meyer-Lindenberg A. Machine Learning for Precision Psychiatry: Opportunities and Challenges. *Biol Psychiatry Cogn Neurosci Neuroimaging*. 2018;3(3):223–30.
8. Braun U, Schaefer A, Betzel RF, Tost H, Meyer-Lindenberg A, Bassett DS. From Maps to Multi-dimensional Network Mechanisms of Mental Disorders. *Neuron*. 2018;97(1):14–31.
9. Dwyer DB, Falkai P, Koutsouleris N. Machine Learning Approaches for Clinical Psychology and Psychiatry. *Annu Rev Clin Psychol*. 2018;14:91–118.
10. Doraiswamy PM, Blease C, Bodner K. Artificial intelligence and the future of psychiatry: Insights from a global physician survey. *Artif Intell Med*. 2020;102:101753.
11. Meinke C, Lueken U, Walter H, Hilbert K. Predicting treatment outcome based on resting-state functional connectivity in internalizing mental disorders: A systematic review and meta-analysis. *Neurosci Biobehav Rev*. 2024;160:105640.
12. Briganti G. Artificial Intelligence in Psychiatry. *Psychiatr Danub*. 2023;35(Suppl 2):15–9.
13. Durstewitz D, Koppe G, Meyer-Lindenberg A. Deep neural networks in psychiatry. *Mol Psychiatry*. 2019;24(11):1583–98.
14. Moher D, Liberati A, Tetzlaff J, Altman DG, PRISMA Group. Preferred reporting items for systematic reviews and meta-analyses: the PRISMA statement. *PLoS Med*. 2009;6(7):e1000097.
15. Guyatt GH, Oxman AD, Vist GE, Kunz R, Falck-Ytter Y, Alonso-Coello P, et al. GRADE: an emerging consensus on rating quality of evidence and strength of recommendations. *BMJ*. 2008;336(7650):924–6.
16. Briganti G. Intelligence artificielle: une introduction pour les cliniciens. *Revue des Maladies Respiratoires*. 2023;40(4):308–13.
17. Bzdok D, Altman N, Krzywinski M. Statistics versus machine learning. *Nat Methods*. 2018;15(4):233–4.
18. Passos IC, Ballester PL, Barros RC, Librenza-Garcia D, Mwangi B, Birmaher B, et al. Machine learning and big data analytics in bipolar disorder: A position paper from the International Society for Bipolar Disorders Big Data Task Force. *Bipolar Disord*. 2019;21(7):582–94.
19. Nickson D, Meyer C, Walasek L, Toro C. Prediction and diagnosis of depression using machine learning with electronic health records data: a systematic review. *BMC Med Inform Decis Mak*. 2023;23(1):271.
20. Park JH, Cho HE, Kim JH, Wall M, Stern Y, Lim H, et al. Machine Learning Prediction of Incidence of Alzheimer's Disease Using Large-Scale Administrative Health Data [Internet]. *bioRxiv*; 2020 [citado el 11 de noviembre de 2024]. p. 625582. Disponible en: <https://www.biorxiv.org/content/10.1101/625582v2>
21. Liu Y, Chen PHC, Krause J, Peng L. How to Read Articles That Use Machine Learning: Users' Guides to the Medical Literature. *JAMA*. 2019;322(18):1806–16.
22. Lee EE, Torous J, Choudhury MD, Depp CA, Graham SA, Kim HC, et al. Artificial Intelligence for Mental Healthcare: Clinical Applications, Barriers, Facilitators, and Artificial Wisdom. *Biological psychiatry Cognitive neuroscience and neuroimaging*. 2021;6(9):856.
23. Koleck TA, Dreisbach C, Bourne PE, Bakken S. Natural language processing of symptoms documented in free-text narratives of electronic health records: a systematic review. *J Am Med Inform Assoc*. 2019;26(4):364–79.
24. Sheikhalishahi S, Miotto R, Dudley JT, Lavelli A, Rinaldi F, Osmani V. Natural Language Processing of Clinical Notes on Chronic Diseases: Systematic Review. *JMIR Med Inform*. 2019;7(2):e12239.
25. McCoy TH, Pellegrini AM, Perlis RH. Research Domain Criteria scores estimated through natural language processing are associated with risk for suicide and accidental death. *Depress Anxiety*. 2019;36(5):392–9.
26. Coppersmith G, Leary R, Crutchley P, Fine A. Natural Language Processing of Social Media as Screening for Suicide Risk. *Biomedical Informatics Insights*. 2018;10:1178222618792860.
27. Stewart R, Velupillai S. Applied natural language processing in mental health big data. *Neuropsychopharmacology*. 2021;46(1):252–3.
28. Akkus Z, Galimzianova A, Hoogi A, Rubin DL, Erickson BJ. Deep Learning for Brain MRI Segmentation: State of the Art and Future Directions. *J Digit Imaging*. 2017;30(4):449–59.
29. Liu Z, Kainth K, Zhou A, Deyer TW, Fayad ZA, Greenspan H, et al. A review of self-supervised, generative, and few-shot deep learning methods for data-limited magnetic resonance imaging segmentation. *NMR Biomed*. 2024;37(8):e5143.
30. Briganti G. A Doctor's Guide to Foundation Models [Internet]. *OSF*; 2023 [citado el 11 de noviembre de 2024]. Disponible en: <https://osf.io/5zg3q>
31. Shin H, Kang Y, Choi KW, Kim S, Ham BJ, Choi Y. Artificial Intelligence-Based Major Depressive Disorder (MDD) Diagnosis Using Raman Spectroscopic Features of Plasma Exosomes. *Anal Chem*. 2023;95(15):6410–6.
32. Noda Y, Sakaue K, Wada M, Takano M, Nakajima S. Development of Artificial Intelligence for Determining Major Depressive Disorder Based on Resting-State EEG and Single-Pulse Transcranial Magnetic Stimulation-Evoked EEG Indices. *J Pers Med*. 2024;14(1):101.
33. Allesøe RL, Nudel R, Thompson WK, Wang Y, Nordentoft M, Børglum AD, et al. Deep learning-based integration of genetics with registry data for stratification of schizophrenia and depression. *Sci Adv*. 2022;8(26):eabi7293.
34. Chan CC, Norel R, Agurto C, Lysaker PH, Myers EJ, Hazlett EA, et al. Emergence of Language Related to Self-experience and

- Agency in Autobiographical Narratives of Individuals With Schizophrenia. *Schizophrenia Bulletin*. 2023;49(2):444–53.
35. Fu J, Yang S, He F, He L, Li Y, Zhang J, et al. Sch-net: a deep learning architecture for automatic detection of schizophrenia. *Biomed Eng Online*. 2021;20(1):75.
  36. Huang J, Zhao Y, Qu W, Tian Z, Tan Y, Wang Z, et al. Automatic recognition of schizophrenia from facial videos using 3D convolutional neural network. *Asian J Psychiatr*. 2022;77:103263.
  37. Dobarjeh M, Dobarjeh Z, Merkin A, Bahrami H, Sumich A, Krishnamurthi R, et al. Personalised predictive modelling with brain-inspired spiking neural networks of longitudinal MRI neuroimaging data and the case study of dementia. *Neural Netw*. 2021;144:522–39.
  38. James C, Ranson JM, Everson R, Llewellyn DJ. Performance of Machine Learning Algorithms for Predicting Progression to Dementia in Memory Clinic Patients. *JAMA Netw Open*. 2021;4(12):e2136553.
  39. You J, Zhang YR, Wang HF, Yang M, Feng JF, Yu JT, et al. Development of a novel dementia risk prediction model in the general population: A large, longitudinal, population-based machine-learning study. *EClinicalMedicine*. 2022;53:101665.
  40. Salehi AW, Baglat P, Sharma BB, Gupta G, Upadhy A. A CNN Model: Earlier Diagnosis and Classification of Alzheimer Disease using MRI. En: 2020 International Conference on Smart Electronics and Communication (ICOSEC) [Internet]. 2020 [citado el 8 de enero de 2025]. p. 156–61. Disponible en: <https://ieeexplore.ieee.org/document/9215402>
  41. Wei Q, Cao H, Shi Y, Xu X, Li T. Machine learning based on eye-tracking data to identify Autism Spectrum Disorder: A systematic review and meta-analysis. *J Biomed Inform*. 2023;137:104254.
  42. Afshar M, Sharma B, Dligach D, Oguss M, Brown R, Chhabra N, et al. Development and multimodal validation of a substance misuse algorithm for referral to treatment using artificial intelligence (SMART-AI): a retrospective deep learning study. *Lancet Digit Health*. junio de 2022;4(6):e426–35.
  43. Gomeni R, Bressolle-Gomeni F, Fava M. Artificial intelligence approach for the analysis of placebo-controlled clinical trials in major depressive disorders accounting for individual propensity to respond to placebo. *Transl Psychiatry*. 2023;13(1):141.
  44. Joyce JB, Grant CW, Liu D, MahmoudianDehkordi S, Kaddurah-Daouk R, Skime M, et al. Multi-omics driven predictions of response to acute phase combination antidepressant therapy: a machine learning approach with cross-trial replication. *Transl Psychiatry*. 2021;11(1):513.
  45. Taliaz D, Spinrad A, Barzilay R, Barnett-Itzhaki Z, Averbuch D, Teltsh O, et al. Optimizing prediction of response to antidepressant medications using machine learning and integrated genetic, clinical, and demographic data. *Transl Psychiatry*. 2021;11(1):381.
  46. Sadeh-Sharvit S, Camp TD, Horton SE, Hefner JD, Berry JM, Grossman E, et al. Effects of an Artificial Intelligence Platform for Behavioral Interventions on Depression and Anxiety Symptoms: Randomized Clinical Trial. *J Med Internet Res*. 2023;25:e46781.
  47. Wang M, Hu K, Fan L, Yan H, Li P, Jiang T, et al. Predicting Treatment Response in Schizophrenia With Magnetic Resonance Imaging and Polygenic Risk Score. *Front Genet*. 2022;13:848205.
  48. Tandon R. Controversies in psychiatry practice and research. *Asian J Psychiatr*. 2023;81:103508.
  49. Kelly CJ, Karthikesalingam A, Suleyman M, Corrado G, King D. Key challenges for delivering clinical impact with artificial intelligence. *BMC Med*. 2019;17(1):195.
  50. Walter M, Alizadeh S, Jamalabadi H, Lueken U, Dannlowski U, Walter H, et al. Translational machine learning for psychiatric neuroimaging. *Prog Neuropsychopharmacol Biol Psychiatry*. 2019;91:113–21.
  51. Castelveccchi D. Can we open the black box of AI? *Nature*. 2016;538(7623):20–3.
  52. Ray A, Bhardwaj A, Malik YK, Singh S, Gupta R. Artificial intelligence and Psychiatry: An overview. *Asian J Psychiatr*. 2022;70:103021.
  53. Yew GCK. Trust in and Ethical Design of Carebots: The Case for Ethics of Care. *Int J Soc Robot*. 2021;13(4):629–45.
  54. Blease C, Locher C, Leon-Carlyle M, Doraiswamy M. Artificial intelligence and the future of psychiatry: Qualitative findings from a global physician survey. *Digit Health*. 2020;6:2055207620968355.
  55. Tandon R. Computational psychiatry and the psychopathology of psychosis: Promising leads and blind alleys. *Schizophr Res*. 2023;254:143–5.
  56. Riley P. Three pitfalls to avoid in machine learning. *Nature*. 2019;572(7767):27–9.
  57. Kline A, Wang H, Li Y, Dennis S, Hutch M, Xu Z, et al. Multimodal machine learning in precision health: A scoping review. *NPJ Digit Med*. 2022;5(1):171.
  58. Su C, Xu Z, Pathak J, Wang F. Deep learning in mental health outcome research: a scoping review. *Transl Psychiatry*. 2020;10(1):116.
  59. Sodhani S, Chandar S, Bengio Y. Toward Training Recurrent Neural Networks for Lifelong Learning. *Neural Comput*. 2020;32(1):1–35.
  60. Couckuyt A, Seurinck R, Emmaneel A, Quintelier K, Novak D, Van Gassen S, et al. Challenges in translational machine learning. *Hum Genet*. 2022;141(9):1451–66.
  61. Zhong Y, Lyu YAH, Yu S, Gao YJ, Mi WF, Li JF. The issue of evidence-based medicine and artificial intelligence. *Asian J Psychiatr*. 2023;85:103627.
  62. Hauser TU, Skvortsova V, De Choudhury M, Koutsouleris N. The promise of a model-based psychiatry: building computational models of mental ill health. *Lancet Digit Health*. 2022;4(11):e816–28.
  63. Low DM, Rumker L, Talkar T, Torous J, Cecchi G, Ghosh SS. Natural Language Processing Reveals Vulnerable Mental Health Support Groups and Heightened Health Anxiety on Reddit During COVID-19: Observational Study. *J Med Internet Res*. 2020;22(10):e22635.
  64. Thornton J, D'Souza R, Tandon R. Artificial intelligence and psychiatry research and practice. *Asian J Psychiatr*. 2023;81:103509.
  65. Koutsouleris N, Hauser TU, Skvortsova V, De Choudhury M. From promise to practice: towards the realisation of AI-informed mental health care. *Lancet Digit Health*. 2022;4(11):e829–40.