

## Inteligencia Artificial Generativa como apoyo para la personalización de intervenciones terapéuticas para la depresión: una revisión exploratoria

### *Generative Artificial Intelligence as a support for the personalization of therapeutic interventions for depression: a scoping review*

**Johanna Paola Basantes Insuasti\***  
Profesional Independiente  
Riobamba - Ecuador  
jopaola1990@gmail.com  
<https://orcid.org/0009-0004-6239-6941>

**Diego Paul Corrales Vargas**  
Develops Corrales  
Latacunga - Ecuador  
developscorrales@gmail.com  
<https://orcid.org/0009-0004-5120-0616>

**Verónica Alexandra Villa Yáñez**  
Unidad Educativa Pensionado Olivo  
Riobamba - Ecuador  
veros\_alexandra@hotmail.com  
<https://orcid.org/0000-0003-0731-2384>

\*Correspondencia:  
jopaola1990@gmail.com

**Cómo citar este artículo:**  
Basantes, J., Corrales, D., & Villa, V. (2026). Inteligencia Artificial Generativa como apoyo para la personalización de intervenciones terapéuticas para la depresión: una revisión exploratoria. *Esprint Investigación*, 5(1), 754-773. <https://doi.org/10.61347/ei.v5i1.283>

**Recibido:** 18 de marzo de 2026

**Aceptado:** 17 de abril de 2026

**Publicado:** 24 de abril de 2026

**Copyright:** Derechos de autor 2026 Johanna Paola Basantes Insuasti, Diego Paul Corrales Vargas, Verónica Alexandra Villa Yáñez.



Esta obra está bajo una licencia internacional Creative Commons Atribución-NonComercial 4.0.

**Resumen:** La depresión constituye un problema prioritario de salud pública y, ante la heterogeneidad de la respuesta terapéutica y las barreras de acceso, la inteligencia artificial generativa ha emergido como una alternativa prometedora para apoyar la personalización de intervenciones clínicas. El objetivo de esta revisión exploratoria fue mapear, sintetizar y analizar críticamente la evidencia disponible sobre el uso de la inteligencia artificial generativa en la personalización de intervenciones terapéuticas para la depresión. Se siguieron las directrices PRISMA-ScR y se realizaron búsquedas en las bases de datos Scopus, PubMed y Web of Science sin restricciones de idioma ni de año de publicación. Se recuperaron 47 registros, de los cuales, tras la eliminación de duplicados y el proceso de selección por títulos, resúmenes y texto completo, se incluyeron finalmente 10 estudios originales. Los resultados mostraron una clara predominancia de chatbots terapéuticos basados en modelos de lenguaje a gran escala, así como enfoques híbridos con recuperación de información, monitoreo contextual y aplicaciones multimodales. Asimismo, se identificó que la personalización se implementó principalmente a través de estrategias dinámicas, contextuales, intraindividuales y participativas, orientadas al apoyo emocional, la psicoeducación, la activación conductual, la terapia cognitivo-conductual y la toma de decisiones clínicas. No obstante, persistieron limitaciones relacionadas con tamaños de muestra reducidos, validación clínica insuficiente, presencia de sesgos en los datos, necesidad de supervisión humana, desafíos éticos y barreras de implementación. En conclusión, la inteligencia artificial generativa presenta un potencial significativo para fortalecer las intervenciones terapéuticas personalizadas en la depresión; sin embargo, su adopción clínica requiere el fortalecimiento de la robustez metodológica, la validación en contextos reales y el desarrollo de marcos de seguridad más sólidos.

**Palabras clave:** Depresión, inteligencia artificial generativa, personalización, psicoterapia digital, salud mental.

**Abstract:** Depression constitutes a major public health concern and, given the heterogeneity of therapeutic response and existing access barriers, generative artificial intelligence has emerged as a promising alternative to support the personalization of clinical interventions. The objective of this scoping review was to map, synthesize, and critically analyze the available evidence on the use of generative artificial intelligence in the personalization of therapeutic interventions for depression. The PRISMA-ScR guidelines were followed, and searches were conducted in the Scopus, PubMed, and Web of Science databases without restrictions on language or year of publication. A total of 47 records were retrieved, of which, after duplicate removal and screening by titles, abstracts, and full texts, 10 original studies were ultimately included. The results showed a clear predominance of therapeutic chatbots based on large language models, as well as hybrid approaches incorporating information retrieval, contextual monitoring, and multimodal applications. Furthermore, personalization was found to be primarily implemented through dynamic, contextual, intra-individual, and participatory strategies, aimed at emotional support, psychoeducation, behavioral activation, cognitive behavioral therapy, and clinical decision-making. However, limitations persisted, including small sample sizes, insufficient clinical validation, data biases, the need for human supervision, ethical challenges, and implementation barriers. In conclusion, generative artificial intelligence demonstrates significant potential to enhance personalized therapeutic interventions for depression; however, its clinical adoption requires strengthened methodological robustness, validation in real-world settings, and the development of more robust safety frameworks.

**Keywords:** Depression, digital psychotherapy, generative artificial intelligence, mental health, personalization.

## 1. Introducción

La depresión constituye uno de los principales desafíos de salud pública a nivel mundial, afectando a millones de personas y generando una carga significativa en términos de discapacidad, calidad de vida y mortalidad (Chen et al., 2025; Zhao et al., 2025). Se estima que el 4% de la población experimenta depresión, siendo esta condición más frecuente en mujeres que en hombres (OMS, 2025). Además, su impacto trasciende el ámbito clínico, ya que incide negativamente en la productividad laboral, las relaciones sociales y el funcionamiento de los sistemas de salud (Xu et al., 2025).

Los tratamientos tradicionales para este trastorno incluyen intervenciones farmacológicas, como los antidepresivos, y terapias psicológicas, como la terapia cognitivo-conductual, las cuales tienen como objetivo reducir los síntomas y mejorar el funcionamiento psicosocial (Gautam et al., 2020; Saelens et al., 2025). Sin embargo, estas intervenciones presentan limitaciones importantes, entre ellas la variabilidad en la respuesta terapéutica, la presencia de efectos secundarios, las barreras de acceso y la escasez de profesionales en salud mental (Gkintoni et al., 2025). Además, los enfoques tradicionales suelen carecer de un nivel adecuado de personalización para abordar la heterogeneidad de los pacientes, lo que puede reducir su efectividad en contextos reales (Comai et al., 2025).

En este contexto, la inteligencia artificial (IA) emerge como una herramienta prometedora en el ámbito de la salud mental, al permitir optimizar procesos de diagnóstico, monitoreo y tratamiento de diversos trastornos (Cruz-Gonzalez et al., 2025). Las técnicas de aprendizaje automático y procesamiento de lenguaje natural han demostrado la capacidad de analizar grandes volúmenes de datos clínicos y conductuales, facilitando la detección temprana de síntomas y la predicción de riesgos (Ali et al., 2025). Asimismo, la IA ha permitido el desarrollo de intervenciones digitales escalables, como aplicaciones móviles y plataformas de telepsiquiatría, que contribuyen a ampliar el acceso a servicios de salud mental (Bobkov et al., 2025; Ni & Jia, 2025).

En los últimos años, la IA generativa ha transformado el panorama de la salud digital al introducir modelos capaces de generar texto, imágenes y otros tipos de contenido de manera autónoma (Kolding et al., 2025). En el ámbito de la salud mental, estas tecnologías se han aplicado en chatbots terapéuticos, sistemas de apoyo emocional y herramientas de psicoeducación, mostrando un potencial significativo para ofrecer intervenciones personalizadas, accesibles y escalables (Zhang et al., 2025). Asimismo, los sistemas basados en IA generativa pueden adaptar sus respuestas en tiempo real según el contexto del usuario, lo que favorece una interacción más natural, dinámica y centrada en el paciente (King et al., 2023).

Los modelos generativos son algoritmos diseñados para replicar patrones complejos en los datos mediante la generación de nuevas muestras que se asemejan al conjunto de datos original (Saish et al., 2025). De acuerdo con Prasad et al. (2025), los modelos Transformers, Variational Autoencoders (VAEs), Diffusion Models y Generative Adversarial Networks (GANs) se basan en sólidos principios matemáticos que les permiten aprender patrones complejos y generar resultados sintéticos de alta calidad. A continuación, se presentan algunos de los principales fundamentos matemáticos que sustentan estos modelos:

- a) Distribuciones de probabilidad y estimación de densidad

$$\theta^* = \arg \max_{\theta} \sum_{i=1}^N \log p(x_i; \theta) \quad (1)$$

- b) Máxima verosimilitud (MLE)

$$\theta^* = \arg \max_{\theta} \prod_{i=1}^N \log p(x_i; \theta) \quad (2)$$

c) Modelos de variables latentes e inferencia variacional (VI)  $\log p(x) \geq \mathbb{E}_{q(z|x)}[\log p(x|z)] - D_{KL}(q(z|x) || p(z))$  (3)

d) Función objetivo minimax (GANs)  $\min_G \max_D \mathbb{E}_{x \sim p_{data}(x)}[\log D(x)] + \mathbb{E}_{z \sim p_Z(z)}[\log (1 - D(G(z)))]$  (4)

e) Mecanismo de autoatención en Transformers  $Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V$  (5)

f) Procesos de difusión en modelos generativos  $Forward Process: q(x_t|x_{t-1}) = \mathcal{N}(x_t; \sqrt{1 - \beta_t} x_{t-1}, \beta_t I)$  (6)

$Reverse Process: p_\theta(x_{t-1}|x_t) = \mathcal{N}\left(x_{t-1}; \mu_\theta(x_t, t), \sum_\theta(x_t, t)\right)$  (7)

Varios autores abordan la tendencia creciente de la IA generativa desde múltiples perspectivas. Wang et al. (2025) realizaron una revisión sistemática centrada en la evaluación de modelos de IA generativa en salud mental, analizando múltiples estudios sobre chatbots y sistemas basados en LLMs. Los autores encontraron que estas tecnologías muestran un alto potencial para proporcionar apoyo emocional y facilitar intervenciones terapéuticas; sin embargo, señalan limitaciones relacionadas con la calidad de la evidencia, la falta de validación clínica robusta y preocupaciones en torno a la seguridad de los usuarios. Además, subrayan la necesidad de estudios longitudinales que evalúen los efectos a largo plazo de estas intervenciones.

Asimismo, Li et al. (2023) llevaron a cabo una revisión sistemática y metaanálisis sobre agentes conversacionales basados en IA para la salud mental. Sus resultados indican que estos sistemas pueden reducir significativamente los síntomas de depresión y ansiedad, con tamaños de efecto moderados, especialmente cuando se integran en plataformas móviles y utilizan enfoques multimodales. No obstante, se identifican limitaciones asociadas a la heterogeneidad metodológica de los estudios, la falta de estandarización de las intervenciones y la escasez de evidencia longitudinal.

Por su parte, Kolding et al. (2025) desarrollaron una revisión sistemática enfocada en el uso de IA generativa en psiquiatría, destacando su rápido crecimiento y diversidad de aplicaciones. El estudio concluye que, aunque estas tecnologías muestran un rendimiento prometedor en tareas como la evaluación clínica y el apoyo terapéutico, su implementación enfrenta desafíos relacionados con aspectos éticos, riesgos de sesgo algorítmico y falta de transparencia en los modelos. Asimismo, se enfatiza la necesidad de involucrar a pacientes y profesionales en el diseño de estas herramientas para mejorar su aceptación y efectividad.

A pesar del creciente interés en la aplicación de la inteligencia artificial generativa en salud mental, persiste una brecha en la literatura científica en cuanto a la integración sistemática de evidencia que aborde específicamente su uso en la personalización de intervenciones terapéuticas para la depresión, considerando simultáneamente los enfoques tecnológicos, los mecanismos de integración clínica, las estrategias de personalización y la evidencia sobre efectividad, usabilidad y seguridad.

En este contexto, el presente estudio tiene como objetivo mapear, sintetizar y analizar críticamente la evidencia disponible sobre el uso de la inteligencia artificial generativa en el diseño e implementación de intervenciones terapéuticas personalizadas para la depresión, con el fin de proporcionar una visión comprensiva del estado actual del campo y orientar futuras líneas de investigación y desarrollo.

Para ello, se plantean las siguientes preguntas de investigación: (1) ¿Qué enfoques de inteligencia artificial generativa se están utilizando para apoyar intervenciones terapéuticas en depresión?; (2)

¿Cómo se integran los sistemas de inteligencia artificial generativa en dichas intervenciones?; (3) ¿Qué estrategias de personalización se implementan en estos sistemas para adaptar las intervenciones terapéuticas a pacientes con depresión?; y (4) ¿Qué limitaciones se reportan con respecto a la adopción de estos sistemas en el ámbito de la salud mental?

## 2. Metodología

La presente investigación se desarrolló como una revisión exploratoria (scoping review) siguiendo las directrices metodológicas establecidas por la extensión PRISMA para revisiones exploratorias (PRISMA-ScR), con el propósito de mapear sistemáticamente la evidencia disponible. Dado que la inteligencia artificial generativa (GenAI) ha emergido recientemente en el ámbito de la investigación, existe una cantidad limitada de literatura consolidada que respalde un enfoque sistemático tradicional de revisión. En este sentido, se consideró que una revisión exploratoria constituía el enfoque metodológico más adecuado (Tricco et al., 2018).

### Criterios de elegibilidad

Se incluyeron estudios originales que abordaron explícitamente el uso de inteligencia artificial generativa en el contexto de intervenciones terapéuticas o tratamiento de la depresión, con algún grado de personalización, adaptación o individualización del proceso terapéutico. Se consideraron investigaciones empíricas que utilizaron modelos generativos, tales como modelos de lenguaje a gran escala o sistemas conversacionales avanzados, aplicados a la salud mental o específicamente a la depresión. No se establecieron restricciones en cuanto al idioma ni al año de publicación, debido al carácter reciente y emergente del tema, lo que permitió capturar la totalidad de la evidencia disponible hasta la fecha de consulta (16 de abril de 2024).

Se excluyeron estudios de tipo revisión (sistemáticas, narrativas o metaanálisis), editoriales, cartas al editor, opiniones, libros, resúmenes de conferencias y documentos sin revisión por pares. Asimismo, se excluyeron aquellos estudios que, aunque abordaban la inteligencia artificial en salud mental, no empleaban enfoques generativos o no estaban orientados específicamente a intervenciones terapéuticas en depresión. También se descartaron aquellos documentos que no pudieron ser recuperados en texto completo.

### Fuentes de información y estrategia de búsqueda

Se emplearon las bases de datos científicas Scopus, PubMed y Web of Science, las cuales fueron seleccionadas por su amplia cobertura de literatura biomédica, tecnológica y multidisciplinaria de alto impacto. Estas bases de datos permitieron la recuperación de estudios relevantes indexados en revistas revisadas por pares, lo que contribuyó a garantizar la calidad y pertinencia de la evidencia incluida en el análisis.

La estrategia de búsqueda se diseñó a partir de cuatro categorías conceptuales principales: "inteligencia artificial generativa", "personalización", "tratamiento" y "depresión". La búsqueda se realizó utilizando el campo de título (TITLE) para los términos relacionados con inteligencia artificial generativa, con el objetivo de maximizar la especificidad en la recuperación de estudios directamente enfocados en esta tecnología, mientras que para las demás categorías se empleó el campo título-resumen-palabras clave (TITLE-ABS-KEY), lo que permitió incrementar la sensibilidad de la búsqueda. La cadena de búsqueda fue adaptada a las particularidades sintácticas de cada base de datos, manteniendo la equivalencia conceptual entre términos.

La tabla 1 presenta la estrategia de búsqueda aplicada por base de datos y el número de estudios recuperados.

**Tabla 1***Estrategia de búsqueda*

Base de datos	Cadena de búsqueda	Estudios
Scopus	( TITLE ( "generative model" OR "generative artificial intelligence" OR "generative AI" OR "large language model*" OR "LLM*" OR "ChatGPT" OR "claude" OR "gemini" OR "llama" ) AND TITLE-ABS-KEY ( "personalized" OR "adaptive" OR "individualized" ) AND TITLE-ABS-KEY ( "therapy" OR "therapeutic intervention*" OR "treatment" OR "psychotherapy" OR "cognitive behavioral therapy" OR CBT OR "mental health intervention*" ) AND TITLE-ABS-KEY ( "depression" OR "depressive" ) ) AND ( LIMIT-TO ( DOCTYPE , "ar" ) )	18
Web of Science	(( "generative model"[Title] OR "generative artificial intelligence"[Title] OR "generative AI"[Title] OR "large language model*"[Title] OR "LLM"[Title] OR "ChatGPT"[Title] OR "claude"[Title] OR "gemini"[Title] OR "llama"[Title] ) AND ( "personalized"[Title/Abstract] OR "adaptive"[Title/Abstract] OR "individualized"[Title/Abstract] ) AND ( "therapy"[Title/Abstract] OR "therapeutic intervention*"[Title/Abstract] OR "treatment"[Title/Abstract] OR "psychotherapy"[Title/Abstract] OR "cognitive behavioral therapy"[Title/Abstract] OR CBT[Title/Abstract] OR "mental health intervention*"[Title/Abstract] ) AND ( "depression"[Title/Abstract] OR "depressive"[Title/Abstract] ) )	14
PubMed	TI=("Generative Model" OR "generative artificial intelligence" OR "generative AI" OR "large language model*" OR "LLM*" OR "ChatGPT" OR "claude" OR "gemini" OR "llama") AND TS=("personalized" OR "adaptive" OR "individualized") AND TS=("therapy" OR "therapeutic intervention*" OR "treatment" OR "psychotherapy" OR "cognitive behavioral therapy" OR CBT OR "mental health intervention*") AND TS=("depression" OR "depressive" )	15
Total		47

### Proceso de selección de estudios

El proceso de selección de estudios se llevó a cabo en varias etapas. Inicialmente, se realizó la eliminación de registros duplicados identificados entre las diferentes bases de datos. Posteriormente, dos revisores evaluaron de manera independiente los títulos y resúmenes de los estudios recuperados, aplicando los criterios de inclusión y exclusión previamente definidos. Los artículos potencialmente relevantes fueron sometidos a revisión a texto completo para confirmar su elegibilidad. En los casos en que surgieron discrepancias entre los revisores, un tercer evaluador intervino para resolverlas y alcanzar consenso, garantizando así la rigurosidad y transparencia del proceso de selección.

### Extracción y síntesis de datos

La extracción de datos se realizó de manera sistemática mediante el uso de una matriz estructurada diseñada específicamente para este estudio, con el fin de garantizar la consistencia y exhaustividad en la recopilación de información relevante. Las variables extraídas de cada estudio incluyeron: autor(es) y año de publicación, país de origen, diseño metodológico, tipo de modelo de inteligencia artificial generativa utilizado, arquitectura o sistema implementado, tipo de intervención terapéutica, características de la población o usuarios, tipo y nivel de personalización, fuentes de datos utilizadas, métricas de evaluación, principales resultados y limitaciones reportadas.

Posteriormente, se llevó a cabo una síntesis narrativa de los datos, en la que se analizaron, interpretaron y compararon los hallazgos de los estudios incluidos, identificando patrones, tendencias y relaciones entre variables. El análisis se estructuró mediante una síntesis temática alineada con las preguntas de investigación, lo que permitió organizar la evidencia de manera coherente y generar una comprensión integral del estado actual del campo. Este enfoque facilitó un análisis exhaustivo, sistemático y crítico de la evidencia empírica disponible sobre el uso de la inteligencia artificial generativa como apoyo para la personalización de intervenciones terapéuticas en la depresión.

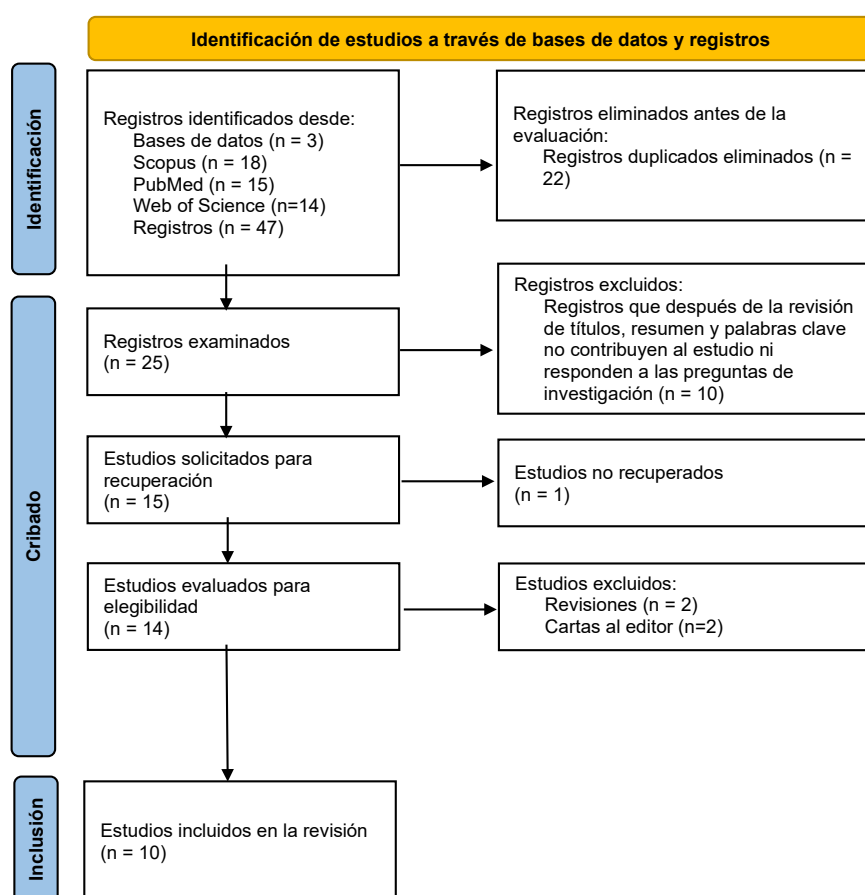
### 3. Resultados

#### Selección de estudios

El proceso de selección de los estudios se presenta de manera esquemática en la Figura 1, mediante el diagrama de flujo PRISMA. En la fase de identificación, la búsqueda arrojó inicialmente 47 registros provenientes de tres bases de datos científicas: 18 de Scopus, 14 de Web of Science y 15 de PubMed. Posteriormente, se realizó la eliminación de duplicados, lo que resultó en la exclusión de 22 registros repetidos y dejó un total de 25 estudios únicos para la fase de cribado.

**Figura 1**

PRISMA flowchart



Durante la etapa de cribado, los 25 registros fueron evaluados mediante la revisión de títulos, resúmenes y palabras clave, fase en la cual se excluyeron 10 estudios que no contribuían al objetivo del estudio ni respondían a las preguntas de investigación. Como resultado, 15 estudios fueron considerados potencialmente elegibles y se procedió a la recuperación de los textos completos.

Sin embargo, un estudio no pudo ser obtenido, por lo que 14 artículos fueron finalmente evaluados en su totalidad para determinar su elegibilidad. En la fase de elegibilidad, los 14 estudios fueron analizados en profundidad de acuerdo con los criterios de inclusión y exclusión establecidos, lo que permitió una evaluación rigurosa de su pertinencia.

En esta etapa final, se excluyeron 4 artículos adicionales por corresponder a revisiones sistemáticas y cartas al editor, lo que resultó en un total final de 10 estudios incluidos, los cuales cumplieron con los criterios de inclusión establecidos y fueron considerados pertinentes para el análisis.

### Característica de los estudios

La tabla 2 presenta las características metodológicas y contextuales de los estudios incluidos, evidenciando una notable heterogeneidad en los diseños de investigación, poblaciones y contextos geográficos. En términos metodológicos, se observa una predominancia de estudios exploratorios, descriptivos y pruebas de concepto, junto con algunos ensayos clínicos aleatorizados y estudios observacionales en entornos reales.

Esta diversidad metodológica refleja el carácter emergente del campo, en el que aún no se ha consolidado un enfoque experimental homogéneo. Asimismo, se identificó la presencia de estudios computacionales y de validación retrospectiva, lo que evidencia la integración de metodologías propias de la ciencia de datos en el ámbito de la salud mental.

En cuanto a la población, existe una amplia variabilidad que abarca desde adolescentes hasta adultos mayores, así como estudios basados en datos simulados o secundarios. Esta heterogeneidad sugiere tanto la versatilidad de las aplicaciones de la inteligencia artificial generativa como la ausencia de criterios estandarizados en la selección de muestras.

Además, los estudios se desarrollaron en diversos contextos geográficos, incluyendo Asia, Europa, América y África, lo que aporta una perspectiva global, aunque con posibles diferencias en la aplicabilidad clínica según el contexto sociocultural.

**Tabla 2**

*Características de los estudios incluidos*

Autor(es)	Tipo de estudio	País	Población
Kang & Hong (2025)	Estudio piloto descriptivo	Corea del Sur	20 jóvenes adultos (18–27 años), 12 mujeres y 8 hombres
Villarreal-Zegarra et al. (2026)	Estudio transversal	Perú	Simulación con 4 investigadores usando perfiles de usuario (sin pacientes reales)
Habicht et al. (2025)	Estudio observacional en contexto clínico real	Reino Unido	244 pacientes (150 intervención con IA, 94 control)
McFadyen et al. (2026)	Ensayo clínico aleatorizado (RCT)	Estados Unidos	Adultos con media de edad aprox. 40 años en ambos grupos
Kim et al. (2025)	Estudio descriptivo y de desarrollo	Corea del Sur	244 participantes; proporción mayor de mujeres en ambos grupos
Fisher et al. (2025)	Proof-of-concept	Estados Unidos	540 adultos (322 intervención, 218 control)

Kulenovic & Lagumdzija-Kulenovic (2025)	Estudio de caso	No especificado	Dataset de 3,874 casos de preguntas-respuestas (adolescentes)
Xu et al. (2025)	Estudio descriptivo computacional y validación retrospectiva	Hong Kong y China	38 adolescentes (13–18 años), subgrupo con datos de sensores
Huang et al. (2025)	Ensayo clínico aleatorizado (RCT)	China	Caso clínico individual: mujer adulta mayor con comorbilidades
Dallison et al. (2025)	Estudio cualitativo exploratorio	Sudáfrica	100 pacientes con diagnóstico de depresión

### Síntesis de resultados

La tabla 3 presenta una síntesis estructurada de los principales resultados, permitiendo una visión comparativa e integrada de los enfoques actuales en el uso de inteligencia artificial generativa para la personalización de intervenciones terapéuticas en la depresión. En particular, se resumen aspectos clave como las fuentes de datos utilizadas, los modelos y sistemas implementados y los tipos de intervenciones terapéuticas abordadas.

Asimismo, se analizan los niveles de personalización alcanzados, las métricas de evaluación empleadas y los principales hallazgos reportados por los estudios incluidos. Este enfoque permitió identificar cómo los sistemas de IA generativa adaptan las intervenciones terapéuticas en función de características individuales de los usuarios, respondiendo directamente al objetivo del estudio.

De manera general, los resultados evidencian que los modelos basados en lenguaje natural, particularmente los LLMs, son los más utilizados para el desarrollo de intervenciones personalizadas, principalmente a través de chatbots terapéuticos, sistemas de apoyo emocional y plataformas digitales de intervención.

Finalmente, la síntesis permitió identificar patrones relevantes, tales como el uso predominante de datos autorreportados, la integración de múltiples fuentes de información y la implementación de estrategias de personalización basadas en perfiles de usuario. No obstante, también se identificaron limitaciones recurrentes, como la falta de validación clínica robusta, la escasa evidencia longitudinal y preocupaciones relacionadas con la ética y la seguridad, lo cual coincide con las preguntas de investigación planteadas.

**Tabla 3***Matriz de resultados*

Autor(es)	Fuente de datos	Modelo(s) de IA generativa	Intervención terapéutica	Nivel de personalización	Métricas de evaluación	Principales resultados
Kang & Hong (2025)	Corpus de síntomas psicopatológicos fundamentado en criterios DSM-5 integrados con OpenAI para detección de riesgos.	HoMemeTown Dr CareSam; chatbot de salud mental que integra el LLM de ChatGPT 4.0 y prompting adaptado.	Gratitud guiada, soporte emocional empático y detección de riesgos en salud mental.	Personalización dinámica basada en la interacción; adaptación de respuestas según emociones expresadas y retroalimentación sobre el diario de gratitud.	Triangulación de datos cuantitativos y cualitativos; usabilidad, satisfacción y competencia del chatbot; positividad, apoyo, empatía, escucha activa, profesionalismo, complejidad y personalización.	Alto nivel de aceptación del chatbot, con puntuaciones elevadas en apoyo, empatía y escucha activa; la personalización fue valorada positivamente, aunque se identificó margen de mejora para lograr intervenciones más individualizadas y contextualmente relevantes.
Villarreal-Zegarra et al. (2026)	Datos clínicos integrados en el sistema, con almacenamiento de sesiones previas, escalas psicológicas y seguimiento de adherencia.	GPT-4o y Llama 3.1-8B; agente conversacional sin fine-tuning ni RAG.	CBT, mindfulness y DBT; psicoeducación, relajación, activación conductual, resolución de problemas y reestructuración cognitiva.	Personalización dinámica y contextual mediante ventana de contexto, seguimiento longitudinal y diseño centrado en el usuario.	Evaluación experta con escala Likert para tono, claridad, exactitud, robustez, completitud, límites, idioma y seguridad; métricas cuantitativas de longitud, diversidad léxica, tokens y costo; análisis de efectos mixtos.	GPT-4o mostró mejor desempeño comunicativo y adaptativo que Llama 3.1-8B; ambas plataformas mantuvieron perfiles de seguridad comparables, y la personalización contextual se consideró prometedora para futuras validaciones clínicas.
Habicht et al. (2025)	Materiales terapéuticos asignados por terapeutas y datos de uso del sistema en el contexto de NHS Talking Therapies.	GPT-4 de OpenAI; chatbot conversacional para apoyo entre sesiones.	CBT grupal guiada por profesionales; apoyo a la resolución de materiales y ejercicios entre sesiones.	Personalización interactiva basada en conversación, con supervisión clínica humana y ajuste a las necesidades del paciente.	Adhesión al tratamiento: asistencia a sesiones, dropouts, Did Not Attend; éxito clínico: mejora fiable, recuperación y recuperación fiable; uso de la aplicación.	La herramienta mejoró la adherencia y se asoció con mejores resultados clínicos frente a materiales estáticos; además, los usuarios reportaron una experiencia más clara, útil y empática.
McFadyen et al. (2026)	Cuestionarios basales y semanales (PHQ-9, GAD-7), datos de compromiso con la intervención y reportes de seguridad de participantes reclutados vía Prolific.	LLM no especificado, gestionado mediante Limbic Layer; sistema Limbic Care con capa cognitiva y clínica.	CBT automatizada con psicoeducación, ejercicios estructurados, sesiones guiadas y soporte emocional no interventivo.	Personalización dinámica y adaptativa en tiempo real según la interacción del usuario.	Compromiso con materiales, frecuencia y duración de uso, síntomas de ansiedad y depresión, eventos adversos, WSAS, MSQ, y escalas de experiencia del usuario.	Se observó mayor compromiso con el tratamiento que en el control; no hubo diferencias globales significativas en síntomas, pero las sesiones guiadas mostraron beneficios exploratorios; la seguridad fue comparable al control.

Autor(es)	Fuente de datos	Modelo(s) de IA generativa	Intervención terapéutica	Nivel de personalización	Métricas de evaluación	Principales resultados
Kim et al. (2025)	3,874 pares pregunta-respuesta de NAVER Knowledge iN, provenientes del Youth Cyber Counseling Center (2014–2024).	GPT-4o mini para generación, all-MiniLM-L12-v2 para embeddings, FAISS para recuperación y Gemini 1.5 Flash para evaluación.	Soporte psicológico personalizado y orientación práctica para adolescentes con depresión, ansiedad, estrés y conflictos relacionales.	Personalización dinámica mediante RAG, con recuperación de los tres casos semánticamente más similares.	Relevancia, empatía, comprensibilidad y practicidad de las respuestas.	Las respuestas generadas fueron más específicas, empáticas y útiles que las no aumentadas; el sistema mostró potencial de escalabilidad y adecuación cultural para intervenciones psicológicas en adolescentes.
Fisher et al. (2025)	Auto-reporte diario ecológico (EMA) y datos pasivos de smartphone: acelerómetro, GPS, movilidad, tiempo fuera de casa y lugares visitados.	GPT-4o de OpenAI, usado para puntuar activación conductual a partir de texto libre.	Terapia de activación conductual (Behavioral Activation, BA) y monitoreo de mecanismos conductuales asociados a depresión.	Personalización intraindividual basada en fluctuaciones respecto a la propia línea base del paciente.	Activación derivada por LLM, BADS-SF, SHAPS, CES-D, afecto positivo y negativo; concordancia con evaluación humana y modelos multivariados.	GPT-4o mostró alta concordancia con la valoración humana y validez convergente con otras medidas digitales; las asociaciones clínicamente relevantes se dieron principalmente a nivel intraindividual, favoreciendo su utilidad para monitoreo personalizado.
Kulenovic & Lagumdzija-Kulenovic (2025)	Base de datos estructurada de medicamentos, interacciones droga-droga, droga-condición, droga-gen, droga-alimento, y criterios STOPP/Beers; además de información clínica del paciente.	ChatGPT 4.0; herramienta analítica PT-TOM para apoyo a la toma de decisiones.	Optimización farmacológica personalizada para el tratamiento de depresión en un paciente geriátrico.	Personalización basada en perfil clínico y farmacológico, con recomendaciones contextualizadas para minimizar riesgos.	Número de reacciones adversas a medicamentos, interacciones críticas y no críticas, interacciones con condiciones y alimentos, y criterios STOPP/Beers.	La herramienta redujo los riesgos farmacológicos y mejoró la alineación con criterios geriátricos; recomendó sustituir citalopram por agomelatina para disminuir riesgos como caídas y prolongación del QT.
Xu et al. (2025)	Datos clínicos de 100 pacientes con depresión: demografía, historia clínica, uso de psicofármacos, escalas SDS, SAS, HAMD, HAMA y protocolos de rTMS.	GPT-3.5-turbo, GPT-4o-mini, LLaMA-3.2-3B, LLaMA-3.3-70B-Instruct; embeddings Bge-large-en-v1.5 y otros modelos; esquema RAG.	Recomendación personalizada de protocolos de estimulación magnética transcranial repetitiva (rTMS) para depresión resistente y MDD.	Personalización basada en recuperación semántica de casos clínicos similares y razonamiento contextualizado.	Exactitud de la recomendación: modo de estimulación, intensidad y duración.	La mejor combinación fue Bge-large-en-v1.5 + GPT-4o-mini, alcanzando 78.18% de precisión; el uso de más ejemplos mejoró la recomendación y la interpretabilidad clínica.

Autor(es)	Fuente de datos	Modelo(s) de IA generativa	Intervención terapéutica	Nivel de personalización	Métricas de evaluación	Principales resultados
Huang et al. (2025)	Interacciones reales con usuarios durante el experimento; no se describe una base de entrenamiento específica.	GPT-4o optimizado con zero-shot learning y chain-of-thought.	Consejería psicológica integrativa para depresión, con selección dinámica de técnicas terapéuticas.	Personalización dinámica basada en el análisis del problema del usuario y selección de enfoque terapéutico apropiado.	Cumplimiento, profesionalismo, entendimiento emocional y empatía, consistencia y coherencia, y seguridad.	El sistema mejoró habilidades conversacionales y redujo síntomas depresivos en un ensayo controlado; no obstante, el profesionalismo y la persistencia de efectos a largo plazo siguieron siendo limitados.
Dallison et al. (2025)	Contenidos co-creados por adolescentes en talleres con IA generativa; materiales previos de la app Kuamsha.	ChatGPT (gpt-3.5-turbo-0301), MidJourney v4 y Soundful.	Terapia de activación conductual en una app narrativa gamificada para adolescentes.	Personalización interactiva dirigida por el usuario mediante co-diseño de historias, imágenes y música.	Análisis temático cualitativo, experiencia del usuario, disfrute, autonomía, percepción estética, relevancia cultural y consideraciones éticas.	La co-creación con IA generó alta aceptación, disfrute y sentido de propiedad; la mayoría prefirió contenidos generados por IA, aunque se requirió apoyo humano para formular prompts y fortalecer la integración terapéutica explícita.

*Nota.* LLM = large language model; CBT = cognitive behavioral therapy; DBT = dialectical behavior therapy; RAG = retrieval-augmented generation; EMA = ecological momentary assessment; PHQ-9 = Patient Health Questionnaire-9; GAD-7 = Generalized Anxiety Disorder-7; BADS-SF = Behavioral Activation for Depression Scale – Short Form; SHAPS = Snaith-Hamilton Pleasure Scale; CES-D = Center for Epidemiologic Studies Depression Scale; WSAS = Work and Social Adjustment Scale; MSQ = Mini Sleep Questionnaire; SDS = Self-Rating Depression Scale; SAS = Self-Rating Anxiety Scale; HAMD = Hamilton Depression Rating Scale; HAMA = Hamilton Anxiety Rating Scale; rTMS = repetitive transcranial magnetic stimulation; DDI = drug-drug interaction; DCI = drug-condition interaction; DGI = drug-gene interaction; DFI = drug-food interaction; STOPP = Screening Tool of Older Persons' Prescriptions; Beers = Beers Criteria; DNA = Did Not Attend; BA = Behavioral Activation

## Principales enfoques de inteligencia artificial generativa como apoyo a la personalización de intervenciones terapéuticas en depresión

El enfoque predominante correspondió al uso de chatbots terapéuticos basados en modelos de lenguaje a gran escala (LLMs), los cuales constituyeron la aplicación más extendida en los estudios analizados. Estos sistemas emplearon modelos como GPT-4 o GPT-4o para generar interacciones conversacionales orientadas al apoyo emocional, la psicoeducación y la entrega de intervenciones terapéuticas estructuradas.

Ejemplos representativos incluyeron el chatbot HoMemeTown Dr CareSam basado en ChatGPT 4.0 (Kang & Hong, 2025), el agente conversacional basado en GPT-4 para apoyo entre sesiones terapéuticas (Habicht et al., 2025) y el sistema optimizado con GPT-4o mediante técnicas de prompting avanzado (Huang et al., 2025). Estos desarrollos evidenciaron una tendencia hacia la automatización del acompañamiento terapéutico.

Asimismo, se identificaron enfoques que integraron IA generativa con arquitecturas híbridas basadas en recuperación aumentada (RAG) y sistemas multimodales, con el objetivo de mejorar la precisión, contextualización y personalización de las respuestas (Kim et al., 2025; Xu et al., 2025). Estas arquitecturas permitieron incorporar conocimiento externo y contexto clínico relevante.

Además, se observó el uso de IA generativa como herramienta de apoyo clínico y analítico, particularmente para el análisis de datos y la personalización basada en evidencia (Fisher et al., 2025; Kulenovic & Lagumdzija-Kulenovic, 2025; McFadyen et al., 2026). Finalmente, se identificó un enfoque emergente basado en entornos creativos y multimodales orientados a fomentar la participación del usuario (Dallison et al., 2025), lo que amplió el alcance de estas tecnologías más allá del lenguaje.

### Integración de los sistemas de IA generativa en intervenciones terapéuticas

La integración de los sistemas de inteligencia artificial generativa en intervenciones terapéuticas para la depresión se realizó principalmente a través de interfaces conversacionales que actuaron como extensiones o complementos del proceso terapéutico. Estas interfaces facilitaron la entrega de contenidos clínicos, el acompañamiento emocional y la continuidad del tratamiento.

En varios estudios, los modelos generativos fueron incorporados como chatbots que interactuaron directamente con los pacientes, proporcionando apoyo entre sesiones, guiando ejercicios terapéuticos y reforzando estrategias clínicas previamente definidas (Habicht et al., 2025; Huang et al., 2025; Kang & Hong, 2025; Villarreal-Zegarra et al., 2026). Este tipo de integración evidenció su potencial como complemento a la terapia tradicional.

Adicionalmente, esta integración se extendió hacia sistemas híbridos y contextos clínicos más complejos, donde la IA generativa funcionó como un componente dentro de arquitecturas más amplias de apoyo terapéutico y toma de decisiones (Dallison et al., 2025; Fisher et al., 2025; Kim et al., 2025; Kulenovic & Lagumdzija-Kulenovic, 2025; McFadyen et al., 2026; Xu et al., 2025).

En este sentido, se evidenció una tendencia hacia la integración progresiva de estas tecnologías en ecosistemas digitales de salud, lo que sugiere un cambio en los modelos tradicionales de atención hacia enfoques más digitales, continuos y personalizados.

---

## Estrategias de personalización para adaptar intervenciones terapéuticas en pacientes con depresión

La personalización en estos sistemas se implementó mediante cuatro patrones principales. El primero correspondió a la personalización dinámica basada en la interacción, donde el sistema ajustó sus respuestas en función de los mensajes, emociones o necesidades expresadas por el usuario (Huang et al., 2025; Kang & Hong, 2025; McFadyen et al., 2026).

Este enfoque representó la forma más frecuente de personalización observada, al permitir una adaptación conversacional en tiempo real. En segundo lugar, se identificó la personalización contextual basada en memoria clínica o recuperación de información (Kim et al., 2025; Villarreal-Zegarra et al., 2026; Xu et al., 2025), donde la IA incorporó historial y contexto acumulado.

Un tercer patrón correspondió a la personalización basada en el perfil clínico e intraindividualidad (Fisher et al., 2025; Kulenovic & Lagumdžija-Kulenovic, 2025), en la que la adaptación se construyó a partir de la línea base del paciente, su evolución clínica y características específicas, lo que permitió recomendaciones más seguras y relevantes.

Finalmente, se identificó la personalización participativa o de co-diseño (Dallison et al., 2025), donde el usuario participó activamente en la creación y ajuste de contenidos terapéuticos. En conjunto, estos enfoques evidenciaron un desarrollo progresivo desde ajustes básicos hacia sistemas más complejos y centrados en el usuario.

### Limitaciones en la adopción de estos sistemas basados en IA generativa

Se identificaron múltiples limitaciones reportadas en los estudios incluidos, las cuales fueron agrupadas en dimensiones metodológicas, técnicas, clínicas, éticas y de implementación. La Tabla 4 sintetiza estas limitaciones, organizándolas según su naturaleza, descripción y los estudios que las reportaron.

En términos metodológicos, se evidenciaron limitaciones relacionadas con tamaños de muestra reducidos, diseños no experimentales y falta de validación clínica robusta, lo que restringe la generalización de los resultados. Asimismo, se observaron inconsistencias en la efectividad clínica, particularmente en la sostenibilidad de los efectos terapéuticos.

Desde el punto de vista técnico, se identificaron problemas como sesgos en los datos, ausencia de información multimodal, y limitaciones propias de los modelos generativos, incluyendo alucinaciones y respuestas inconsistentes. Estas limitaciones afectaron la confiabilidad y seguridad de los sistemas.

Finalmente, se destacaron desafíos éticos y de implementación, tales como problemas de privacidad, necesidad de supervisión humana, barreras regulatorias, costos operativos y falta de integración con sistemas de salud. En conjunto, estos hallazgos evidenciaron que, aunque prometedores, estos sistemas aún requieren avances significativos para su adopción clínica segura y efectiva.

**Tabla 4***Limitaciones reportadas por los autores*

Limitación	Descripción	Autor(es)
Tamaño de muestra reducido y baja generalización	Estudios con muestras pequeñas o no representativas que limitan la extrapolación de resultados a poblaciones más amplias.	Kang & Hong (2025); Fisher et al. (2025); Xu et al. (2025b)
Falta de validación clínica robusta	Evaluaciones en entornos simulados o ausencia de ensayos clínicos controlados que confirmen eficacia en contextos reales.	Villarreal-Zegarra et al. (2026); Xu et al. (2025b); McFadyen et al. (2026)
Limitaciones en diseño metodológico	Estudios observacionales, falta de control o ausencia de grupos control adecuados.	Habicht et al. (2025); McFadyen et al. (2026)
Efectividad clínica limitada o inconsistente	Resultados no significativos o efectos terapéuticos de corta duración en algunos contextos.	McFadyen et al. (2026); Huang et al. (2025)
Dependencia de datos y sesgos	Uso de datasets limitados o sesgados que afectan la representatividad y desempeño del modelo.	Kim et al. (2025); Huang et al. (2025); Dallison et al. (2025)
Falta de datos multimodales y contexto clínico completo	Uso de datos clínicos parciales sin integrar dimensiones biológicas o contextuales relevantes.	Xu et al. (2025b); Fisher et al. (2025)
Limitaciones técnicas de los modelos (alucinaciones, inconsistencia)	Generación de respuestas erróneas, inconsistentes o potencialmente dañinas por parte de los LLMs.	Kang & Hong (2025); McFadyen et al. (2026)
Falta de personalización avanzada	Ausencia de técnicas como fine-tuning o RAG que mejoren la adaptación clínica.	Villarreal-Zegarra et al. (2026)
Necesidad de supervisión humana	Los sistemas no son completamente autónomos y requieren validación o guía clínica para su uso seguro.	Habicht et al. (2025); Fisher et al. (2025); Dallison et al. (2025)
Problemas de usabilidad y dependencia del usuario	Necesidad de entrenamiento o apoyo para interactuar eficazmente con los sistemas.	Dallison et al. (2025)
Costos operativos y escalabilidad	Alto costo de modelos avanzados y desafíos para implementar sistemas a gran escala.	Villarreal-Zegarra et al. (2026)
Falta de integración con sistemas de salud	Ausencia de interoperabilidad con historias clínicas y sistemas sanitarios formales.	Kang & Hong (2025); Villarreal-Zegarra et al. (2026)
Barreras regulatorias y normativas	Necesidad de cumplir regulaciones sanitarias para su adopción clínica formal.	Villarreal-Zegarra et al. (2026); Habicht et al. (2025)
Problemas éticos y de privacidad	Riesgos asociados al manejo de datos sensibles, consentimiento y seguridad del paciente.	Kang & Hong (2025); Fisher et al. (2025); Huang et al. (2025); Dallison et al. (2025)
Limitaciones en la relación terapéutica	Dificultad para replicar la alianza terapéutica y el profesionalismo clínico en IA.	Huang et al. (2025); Habicht et al. (2025)
Falta de sostenibilidad de efectos terapéuticos	Beneficios clínicos que no se mantienen en el tiempo sin intervención continua.	Huang et al. (2025)

## 4. Discusión

El presente estudio tuvo como objetivo mapear, sintetizar y analizar críticamente la evidencia existente sobre el uso de la inteligencia artificial generativa en la personalización de intervenciones terapéuticas para la depresión. A través de una revisión exploratoria, se identificaron patrones emergentes y vacíos de investigación en un campo aún incipiente y en rápida evolución. Este enfoque permitió no solo describir el estado actual del conocimiento, sino también problematizar sus alcances y limitaciones.

Los hallazgos muestran que la IA generativa se ha consolidado principalmente a través de sistemas conversacionales basados en modelos de lenguaje a gran escala, integrados como herramientas complementarias dentro de intervenciones terapéuticas digitales. Asimismo, se evidenció una transición progresiva hacia enfoques más complejos, que incorporan recuperación de información, monitoreo en tiempo real y personalización contextual. Sin embargo, la personalización identificada continúa siendo mayoritariamente reactiva y limitada, lo que restringe su impacto clínico potencial.

En este sentido, persisten desafíos estructurales relevantes, relacionados con la validación clínica, la seguridad, la escalabilidad y la integración en sistemas de salud. Estos hallazgos sugieren que, si bien la IA generativa presenta un alto potencial transformador, su implementación aún no alcanza un nivel de madurez suficiente para su adopción clínica generalizada.

Los resultados de este estudio son consistentes con revisiones sistemáticas recientes que destacan el papel central de los chatbots basados en IA generativa en salud mental. Zhang et al. (2025) reportaron que los chatbots generativos representan la aplicación más extendida en intervenciones psicológicas digitales, mostrando efectos positivos modestos en la reducción de síntomas depresivos. Este hallazgo refuerza la evidencia de que dichas herramientas poseen utilidad clínica inicial, aunque con impacto aún limitado.

Estos resultados son coherentes con los obtenidos en el presente estudio, donde los sistemas conversacionales constituyen el enfoque predominante para la implementación de intervenciones terapéuticas. No obstante, la predominancia de este enfoque también evidencia una posible dependencia excesiva de soluciones conversacionales, lo que podría restringir la exploración de enfoques multimodales más integrales.

Asimismo, la integración de la IA generativa como complemento del tratamiento clínico coincide con la evidencia reportada en la literatura reciente. Cruz-Gonzalez et al. (2025) destacan que la IA en salud mental se ha utilizado principalmente en tres dominios: diagnóstico, monitoreo e intervención, funcionando como un soporte para los profesionales de la salud. Esta convergencia sugiere una tendencia hacia modelos de atención híbridos, donde la IA no reemplaza al clínico, sino que amplifica sus capacidades.

De manera similar, Olawade et al. (2024) enfatizan que estas tecnologías permiten ampliar el acceso a servicios de salud mental, pero requieren integración con sistemas clínicos existentes y supervisión humana para garantizar su efectividad y seguridad. Este planteamiento respalda los resultados obtenidos, donde la IA generativa se posicionó como una herramienta complementaria más que sustitutiva dentro de los modelos de atención.

En cuanto a las estrategias de personalización, los hallazgos evidencian una brecha significativa entre el potencial teórico de la IA generativa y su aplicación práctica. Aunque los modelos generativos pueden adaptar respuestas en función del contexto conversacional, la mayoría de los sistemas carecen de integración profunda con datos clínicos, biomarcadores o información longitudinal, lo que limita su capacidad de personalización real (Wang et al., 2025).

Asimismo, estudios sobre agentes conversacionales destacan que la personalización suele limitarse a ajustes superficiales basados en entradas del usuario, sin alcanzar un nivel de medicina verdaderamente personalizada o de precisión (Jabir et al., 2023). Esto coincide con los resultados del presente estudio, donde la personalización se basó principalmente en interacción dinámica, recuperación de contexto o adaptación intraindividual, sin integración de modelos clínicos robustos.

Desde una perspectiva crítica, estos hallazgos ponen de manifiesto la necesidad de avanzar hacia enfoques más integrales, que combinen IA generativa con datos clínicos estructurados, sensores digitales y sistemas de historia clínica electrónica. La evolución hacia modelos multimodales y longitudinales podría constituir un elemento clave para el desarrollo de intervenciones terapéuticas verdaderamente personalizadas.

### Limitaciones

El presente estudio presenta algunas limitaciones que deben ser consideradas al interpretar sus resultados. La búsqueda se restringió a las bases de datos Scopus, Web of Science y PubMed, lo que podría haber limitado la identificación de estudios relevantes indexados en otras fuentes, afectando potencialmente la exhaustividad de la evidencia recopilada.

Asimismo, el tema abordado corresponde a un campo emergente, caracterizado por un desarrollo reciente y una rápida evolución tecnológica, lo que implica que la evidencia disponible es aún limitada, heterogénea y en constante expansión. Esta situación dificulta la consolidación de conclusiones definitivas y comparaciones estandarizadas entre estudios.

Finalmente, el bajo número de estudios incluidos reflejó tanto la novedad del área como la escasez de investigaciones empíricas robustas, lo que limita la generalización de los hallazgos. En este sentido, se hace evidente la necesidad de desarrollar estudios longitudinales, ensayos clínicos controlados y marcos de evaluación estandarizados.

En consecuencia, futuras investigaciones deberán centrarse en validar clínicamente estas tecnologías, mejorar su integración en sistemas de salud y fortalecer sus capacidades de personalización, con el fin de consolidar el potencial de la inteligencia artificial generativa en la intervención terapéutica de la depresión.

## 5. Conclusiones

Los enfoques de inteligencia artificial generativa identificados evidenciaron una clara convergencia hacia sistemas conversacionales basados en modelos de lenguaje a gran escala, los cuales se consolidaron como el eje central de las intervenciones analizadas, complementados por arquitecturas híbridas con recuperación de información y, en menor medida, por aplicaciones multimodales y de apoyo clínico. La evidencia sugiere que el campo se encuentra aún en una fase exploratoria, aunque ya se observa una transición progresiva desde chatbots genéricos hacia soluciones más contextualizadas, adaptativas y clínicamente orientadas.

La integración de estos sistemas en las intervenciones terapéuticas se ha producido principalmente como un soporte complementario a la atención clínica, ya sea mediante acompañamiento entre sesiones, entrega de ejercicios terapéuticos, orientación psicológica o apoyo en la toma de decisiones. Las estrategias de personalización observadas se basaron predominantemente en la adaptación dinámica a la interacción del usuario, el aprovechamiento del contexto conversacional, la utilización de memoria clínica o recuperación de información, la adaptación intraindividual y el co-diseño de contenidos terapéuticos, lo que refleja un avance gradual hacia modelos más centrados en el paciente.

No obstante, las principales limitaciones reportadas incluyeron tamaños de muestra reducidos, validación clínica insuficiente, dependencia de datos sesgados o limitados, necesidad de supervisión humana, riesgos asociados a la privacidad, altos costos de implementación, problemas de escalabilidad y desafíos regulatorios. En consecuencia, aunque la inteligencia artificial generativa presenta un potencial significativo en el ámbito de la salud mental, su adopción clínica aún requiere el fortalecimiento de la robustez metodológica, la validación en contextos reales y el desarrollo de marcos éticos y de seguridad más sólidos.

En términos prospectivos, se hace imprescindible avanzar hacia estudios longitudinales, ensayos clínicos controlados y modelos multimodales integrados, que permitan consolidar la evidencia científica y optimizar la personalización terapéutica. Asimismo, la integración efectiva con sistemas de salud y la participación activa de profesionales clínicos serán factores determinantes para garantizar una implementación segura, ética y sostenible, posicionando a la IA generativa como un componente clave en el futuro de las intervenciones en salud mental.

## Referencias

- Ali, M., Ali, S., Abbas, Q., Abbas, Z., & Lee, S. (2025). Artificial intelligence for mental health: A narrative review of applications, challenges, and future directions in digital health. *Digital Health, 11*, 20552076251395548. <https://doi.org/10.1177/20552076251395548>
- Bobkov, A., Cheng, F., Xu, J., Bobkova, T., Deng, F., He, J., Jiang, X., Khuzin, D., & Kang, Z. (2025). Telepsychiatry and artificial intelligence: A structured review of emerging approaches to accessible psychiatric care. *Healthcare, 13*(11), 1348. <https://doi.org/10.3390/healthcare13111348>
- Chen, X., Li, F., Zuo, H., & Zhu, F. (2025). Trends in prevalent cases and disability-adjusted life-years of depressive disorders worldwide: Findings from the Global Burden of Disease study from 1990 to 2021. *Depression and Anxiety, 2025*(1), 5553491. <https://doi.org/10.1155/da/5553491>
- Comai, S., Manchia, M., Bosia, M., Miola, A., Poletti, S., Benedetti, F., Nasini, S., Ferri, R., Rujescu, D., Leboyer, M., Licinio, J., Baune, B. T., & Serretti, A. (2025). Moving toward precision and personalized treatment strategies in psychiatry. *International Journal of Neuropsychopharmacology, 28*(5), pyaf025. <https://doi.org/10.1093/ijnp/pyaf025>
- Cruz-Gonzalez, P., He, A., Lam, E., Ng, I., Li, M., Hou, R., Chan, J., Sahni, Y., Guasch, N., Miller, T., Lau, B., & Vidaña, D. (2025). Artificial intelligence in mental health care: A systematic review of diagnosis, monitoring, and intervention applications. *Psychological Medicine, 55*, e18. <https://doi.org/10.1017/S0033291724003295>
- Dallison, S., Moffett, B., Makhubela, P., Nkuna, T., Pozuelo, J. R., Heerden, A. van, & O'Mahen, H. (2025). Using generative AI to co-design digital mental health interventions with adolescents in rural South Africa: Qualitative thematic analysis of participatory workshops. *Journal of Medical Internet Research, 27*(1), e73535. <https://doi.org/10.2196/73535>
- Fisher, H., Jaffe, N., Rahimi-Eichi, H., Forbes, E., Pizzagalli, D., Baker, J., & Webb, C. (2025). Measuring activation during behavioral activation therapy: A proof-of-concept study using smartphone sensors and LLM-derived ratings in adolescents with anhedonia. *NPP—Digital Psychiatry and Neuroscience, 3*(1), 24. <https://doi.org/10.1038/s44277-025-00045-w>
- Gautam, M., Tripathi, A., Deshmukh, D., & Gaur, M. (2020). Cognitive behavioral therapy for depression. *Indian Journal of Psychiatry, 62*(Suppl 2), S223. [https://doi.org/10.4103/psychiatry.IndianJPsychiatry\\_772\\_19](https://doi.org/10.4103/psychiatry.IndianJPsychiatry_772_19)

- Gkintoni, E., Vassilopoulos, S., & Nikolaou, G. (2025). Next-generation cognitive-behavioral therapy for depression: Integrating digital tools, teletherapy, and personalization for enhanced mental health outcomes. *Medicina*, 61(3), 431. <https://doi.org/10.3390/medicina61030431>
- Habicht, J., Dina, L., McFadyen, J., Stylianou, M., Harper, R., Hauser, T., & Rollwage, M. (2025). Generative AI-enabled therapy support tool for improved clinical outcomes and patient engagement in group therapy: Real-world observational study. *Journal of Medical Internet Research*, 27(1), e60435. <https://doi.org/10.2196/60435>
- Huang, F., Ding, H., Li, S., Han, N., Di, Y., Liu, X., Zhao, N., Li, L., & Zhu, T. (2025). Self-help AI psychological counseling system based on large language models and its effectiveness evaluation. *Acta Psychologica Sinica*, 57, 2022. <https://doi.org/10.3724/SP.J.1041.2025.2022>
- Jabir, A., Martinengo, L., Lin, X., Torous, J., Subramaniam, M., & Car, L. (2023). Evaluating conversational agents for mental health: Scoping review of outcomes and outcome measurement instruments. *Journal of Medical Internet Research*, 25(1), e44548. <https://doi.org/10.2196/44548>
- Kang, B., & Hong, M. (2025). Development and evaluation of a mental health chatbot using ChatGPT 4.0: Mixed methods user experience study with Korean users. *JMIR Medical Informatics*, 13(1), e63538. <https://doi.org/10.2196/63538>
- Kim, J., Kim, S., Ahn, J., & Lee, S. (2025). LLM-based response generation for Korean adolescents: A study using the NAVER Knowledge iN Q&A dataset with RAG. *Healthcare Informatics Research*, 31(2), 136–145. <https://doi.org/10.4258/hir.2025.31.2.136>
- King, D., Nanda, G., Stoddard, J., Dempsey, A., Hergert, S., Shore, J., & Torous, J. (2023). An introduction to generative artificial intelligence in mental health care: Considerations and guidance. *Current Psychiatry Reports*, 25(12), 839–846. <https://doi.org/10.1007/s11920-023-01477-x>
- Kolding, S., Lundin, R. M., Hansen, L., & Østergaard, S. D. (2025). Use of generative artificial intelligence (AI) in psychiatry and mental health care: A systematic review. *Acta Neuropsychiatrica*, 37, e37. <https://doi.org/10.1017/neu.2024.50>
- Kulenovic, A., & Lagumdzija-Kulenovic, A. (2025). Minimizing STOPP and Beers criteria risks in PIM treatments using PM-TOM and ChatGPT: A case study. En *Envisioning the future of health informatics and digital health* (pp. 149–153). IOS Press. <https://doi.org/10.3233/SHTI250067>
- Li, H., Zhang, R., Lee, Y., Kraut, R., & Mohr, D. (2023). Systematic review and meta-analysis of AI-based conversational agents for promoting mental health and well-being. *npj Digital Medicine*, 6(1), 236. <https://doi.org/10.1038/s41746-023-00979-5>
- McFadyen, J., Habicht, J., Dina, L., Harper, R., Hauser, T., & Rollwage, M. (2026). Increasing engagement with cognitive-behavioral therapy (CBT) using generative AI: A randomized controlled trial (RCT). *Communications Medicine*, 6(1), 129. <https://doi.org/10.1038/s43856-025-01321-8>
- Ni, Y., & Jia, F. (2025). A scoping review of AI-driven digital interventions in mental health care: Mapping applications across screening, support, monitoring, prevention, and clinical education. *Healthcare*, 13(10), 1205. <https://doi.org/10.3390/healthcare13101205>
- Olawade, D., Wada, O., Odetayo, A., David-Olawade, A., Asaolu, F., & Eberhardt, J. (2024). Enhancing mental health with artificial intelligence: Current trends and future prospects. *Journal of Medicine, Surgery, and Public Health*, 3, 100099. <https://doi.org/10.1016/j.glmedi.2024.100099>

- Organización Mundial de la Salud (OMS). (2025, agosto 29). *Depressive disorder (depression)*. <https://www.who.int/news-room/fact-sheets/detail/depression>
- Prasad, S., Ravikumar, C., Natha, P., & Pau, G. (2025). Exploring the mathematical foundations of generative AI models: VAEs, GANs, transformers, and DMs. *IEEE Access*, *13*, 217962–218009. <https://doi.org/10.1109/ACCESS.2025.3647861>
- Saelens, J., Gramser, A., Watzal, V., Zarate, C. A., Lanzenberger, R., & Kraus, C. (2025). Relative effectiveness of antidepressant treatments in treatment-resistant depression: A systematic review and network meta-analysis of randomized controlled trials. *Neuropsychopharmacology*, *50*(6), 913–919. <https://doi.org/10.1038/s41386-024-02044-5>
- Saish, N., Jayashree, J., & Vijayashree, J. (2025). Mathematical foundations and applications of generative AI models. En N. R. Vajjhala, S. S. Roy, B. Taşçı, & M. E. Hoque Chowdhury (Eds.), *Generative artificial intelligence (AI) approaches for industrial applications* (pp. 19–45). Springer Nature Switzerland. [https://doi.org/10.1007/978-3-031-76710-4\\_2](https://doi.org/10.1007/978-3-031-76710-4_2)
- Tricco, A., Lillie, E., Zarin, W., O'Brien, K., Colquhoun, H., Levac, D., Moher, D., Peters, M., Horsley, T., Weeks, L., Hempel, S., Akl, E., Chang, C., McGowan, J., Stewart, L., Hartling, L., Aldcroft, A., Wilson, M., Garritty, C., ... Straus, S. (2018). PRISMA extension for scoping reviews (PRISMA-ScR): Checklist and explanation. *Annals of Internal Medicine*, *169*(7), 467–473. <https://doi.org/10.7326/M18-0850>
- Villarreal-Zegarra, D., Paredes-Gonzales, Y., Dámaso-Román, A., Quiñones-Inga, J., Centeno-Terrazas, G., & Lozada, Y. (2026). Development, system design, safety, and performance metrics of a conversational agent for reducing depressive and anxious symptoms based on a large language model: The MHAI study. *PLOS ONE*, *21*(3), e0344939. <https://doi.org/10.1371/journal.pone.0344939>
- Wang, L., Bhanushali, T., Huang, Z., Yang, J., Badami, S., & Hightow-Weidman, L. (2025). Evaluating generative AI in mental health: Systematic review of capabilities and limitations. *JMIR Mental Health*, *12*(1), e70014. <https://doi.org/10.2196/70014>
- Xu, J., Han, Z. R., Lv, X., Chen, L., Mao, N., Gao, M. M., Zhang, H., Hu, Y., Qin, S., Gross, J. J., & Zhang, Z. (2025a). A scalable mental health intervention for depressive symptoms: Evidence from a randomized controlled trial and large-scale real-world studies. *npj Digital Medicine*, *8*(1), 491. <https://doi.org/10.1038/s41746-025-01888-5>
- Xu, L., Xie, H., Tao, X., Qin, S. J., Wang, F. L., Gururajan, R., Elangovan, S., & Shen, Y. (2025b). Personalized rTMS treatment recommendation with retrieval-augmented LLM reasoning. *Brain Informatics*, *12*(1), 29. <https://doi.org/10.1186/s40708-025-00275-w>
- Zhang, Q., Zhang, R., Xiong, Y., Sui, Y., Tong, C., & Lin, F.-H. (2025). Generative AI mental health chatbots as therapeutic tools: Systematic review and meta-analysis of their role in reducing mental health issues. *Journal of Medical Internet Research*, *27*(1), e78238. <https://doi.org/10.2196/78238>
- Zhao, L., Lou, Y., Tao, Y., Wang, H., & Xu, N. (2025). Global, regional and national burden of depressive disorders in adolescents and young adults, 1990–2021: Systematic analysis of the global burden of disease study 2021. *Frontiers in Public Health*, *13*. <https://doi.org/10.3389/fpubh.2025.1599602>

---

## Transparencia

### Conflicto de interés

Los autores declaran que no existen conflictos de interés de naturaleza alguna como parte de la presente investigación.

### Fuente de financiamiento

Los autores financiaron completamente la investigación.

### Contribución de autoría

Johanna Paola Basantes Insuasti: Conceptualización, metodología, validación, análisis formal, investigación, gestión de datos, visualización, redacción - preparación del borrador original, redacción - revisión y edición, financiamiento, recursos, supervisión.

Diego Paul Corrales Vargas: Conceptualización, metodología, software, validación, análisis formal, investigación, gestión de datos, redacción - preparación del borrador original, redacción - revisión y edición, financiamiento, administración del proyecto, recursos, supervisión.

Verónica Alexandra Villa Yáñez: Conceptualización, análisis formal, investigación, gestión de datos, redacción - preparación del borrador original, redacción - revisión y edición, financiamiento, recursos.

Los autores contribuyeron activamente en el análisis de los resultados, revisión y aprobación del manuscrito final.