
















Artículo

Implementación del Paradigma de Salud Mental de Precisión en Entornos Reales: Presentación del Proyecto NOVA

Pablo Roca^{1,2} , Martín Sánchez-Pedreño^{1,2} , Sara Noheda-Cifuentes¹ , Eduar S. Ramírez-Riveros^{1,3} ,
Carolina Martín-Azañedo^{1,3} , Fermín Martínez-Zaragoza⁴ , Rosaria M. Zangri^{2,5} ,
Eduardo P. García del Valle^{2,6} , Montserrat León-García⁷ , Derek L. Gravholt⁷ , Ángel Enrique-Roig⁸ ,
Rob Saunders⁹ , Luis Javier Herrera-Maldonado¹⁰ , María del Carmen Pegalajar-Jiménez¹⁰ 
y Sara Rodríguez-Moreno^{1,11} 

¹Universidad Villanueva, Madrid (España)

²Medea Lab, Madrid (España)

³Universidad Francisco de Vitoria, Madrid (España)

⁴Universidad Miguel Hernández, Elche (España)

⁵UNIE Universidad, Madrid (España)

⁶IE Universidad, Madrid (España)

⁷Knowledge and Evaluation (KER) Unit, Mayo Clinic, Rochester, Minnesota (EEUU)

⁸Amwell Science, Boston, Massachusetts (EEUU)

⁹CORE Data Lab, University College London, Londres (Reino Unido)

¹⁰Universidad de Granada (España)

¹¹Universidad Europea de Madrid (España)

INFORMACIÓN

Recibido: 22/01/2026

Aceptado: 30/03/2026

Palabras clave:

Salud mental de precisión

Cuidado basado en la medición

Toma de decisiones basada en datos

Inteligencia artificial

Implementación

RESUMEN

A pesar de que la Práctica Basada en la Evidencia (PBE) ha estandarizado los tratamientos psicológicos, la realidad clínica sigue enfrentándose a una barrera persistente: la dificultad de traducir los resultados de ensayos clínicos grupales a la singularidad de cada paciente en contextos reales. Como respuesta, la Salud Mental de Precisión (SMP) propone una evolución del modelo actual, integrando el cuidado basado en la medición y la toma de decisiones basada en datos para ajustar la intervención a las necesidades específicas de cada persona, gracias en gran medida a desarrollos tecnológicos recientes como la Inteligencia Artificial (IA). En este contexto, el presente artículo persigue dos objetivos fundamentales. En primer lugar, sintetiza los pilares operativos de la SMP, analizando cómo la medición rutinaria y las predicciones algorítmicas pueden potenciar el juicio clínico del profesional. En segundo lugar, se introduce el proyecto NOVA (Navigating Outcomes via Analytics), un proyecto traslacional diseñado para superar las barreras actitudinales, tecnológicas, estadísticas y contextuales de la implementación de herramientas de SMP en España. Se discute sobre los pasos necesarios para cerrar la brecha entre la innovación tecnológica y la práctica asistencial en psicología, acelerando la adopción sostenible de una psicología de precisión en el mundo real.

Citar como: Roca, Pablo; Sánchez-Pedreño, Martín; Noheda-Cifuentes, Sara; Ramírez-Riveros, Eduar S.; Martín-Azañedo, Carolina; Martínez-Zaragoza, Fermín; Zangri, Rosaria M.; García del Valle, Eduardo P.; León-García, Montserrat; Gravholt, Derek L.; Enrique-Roig, Ángel; Saunders, Rob; Herrera-Maldonado, Luis Javier; Pegalajar-Jiménez, María del Carmen, y Rodríguez-Moreno, Sara (2026). Implementación del paradigma de salud mental de precisión en entornos reales: presentación del proyecto NOVA. *Apuntes de Psicología*, 44(2), 69-76. <https://doi.org/10.70478/apuntes.psi.2026.44.08>

Autor y e-mail de correspondencia: Pablo Roca, pablo.roca@medeamind.com

Este artículo está publicado bajo Licencia Creative Commons 4.0 CC-BY-NC-ND

Implementation of the Precision Mental Health Paradigm in Real-World Settings: Presentation of the NOVA Project

ABSTRACT

Keywords:

Precision mental health
Measurement-based care
Data-driven decision-making
Artificial intelligence
Implementation

Although Evidence-Based Practice (EBP) has standardized psychological treatments, clinical practice continues to face a persistent barrier: the difficulty of translating the results of group clinical trials to the unique needs of each patient in real-world settings. In response, Precision Mental Health (PMH) offers a new approach, combining measurement-based care and data-driven decision-making to provide personalised interventions. This evolution is largely possible thanks to recent technological developments, such as Artificial Intelligence (AI). In this context, the article has two key objectives. Firstly, it summarises the operational principles of PMH, analysing how routine measurement and algorithmic predictions can enhance the clinical judgement of healthcare professionals. Secondly, it introduces the NOVA (Navigating Outcomes via Analytics) project, a translational initiative designed to overcome attitudinal, technological, statistical, and contextual barriers to implementing PMH tools in Spain. The article discusses the steps needed to bridge the gap between technological innovation and clinical practice in psychology, with the aim of accelerating the sustainable adoption of precision psychology in the real world.

De la Práctica Basada en la Evidencia a la Salud Mental de Precisión

La Práctica Basada en la Evidencia (PBE) ha dominado el panorama de la salud mental durante las últimas décadas. Gracias a ensayos controlados aleatorizados y guías de práctica clínica (por ejemplo, NICE, APA, OMS), hoy sabemos qué tratamientos son los que mejor funcionan para los diferentes trastornos y patologías. Sin embargo, a pesar de los avances en investigación y los millones de euros invertidos, el tamaño del efecto promedio de los tratamientos psicológicos no ha mejorado en las últimas décadas (Weisz et al., 2019). La evidencia muestra que casi la mitad de los pacientes que realizan terapia psicológica no logran mejoras clínicamente significativas y en torno al 10% experimentan un empeoramiento de los síntomas (Cuijpers et al., 2021; Schwartz et al., 2021). Además, la interrupción unilateral de la terapia por parte del paciente sigue siendo un problema importante, con tasa de abandono terapéutico del 30-40% (Cooper y Conklin, 2015; Roos y Werbart, 2013). Nos enfrentamos a una paradoja tratamiento-prevalencia sin precedentes: aunque la disponibilidad de los tratamientos en salud mental ha aumentado considerablemente desde la década de los 80, la prevalencia de los trastornos mentales continúa en ascenso (Ormel et al., 2022).

Este estancamiento sugiere que el modelo tradicional de PBE, aunque necesario, resulta insuficiente para la práctica clínica real por tres limitaciones fundamentales (DeRubeis et al., 2014; Purgato et al., 2021):

1. Se construye sobre promedios grupales, mientras que los profesionales tratan a individuos. Una intervención eficaz para la “media” puede ser inocua o incluso contraproducente para un paciente concreto.
2. La selección del tratamiento más adecuado para cada paciente sigue realizándose por ensayo y error. Aunque la investigación ha identificado múltiples predictores de resultados, este conocimiento rara vez se traduce en algoritmos prescriptivos que indiquen al profesional qué terapia específica elegir para un perfil determinado.
3. La complejidad de la práctica clínica real excede la simplicidad de las guías clínicas estandarizadas. La comorbilidad, la

historia de tratamientos previos y determinantes contextuales del paciente y los sistemas sanitarios dejan a muchos pacientes sin la ayuda que realmente necesitan, ya que las guías clínicas rara vez especifican cómo personalizar la intervención o cómo pivotar cuando un paciente no responde según lo esperado. Esta falta de precisión y personalización en la atención a la salud mental socava los esfuerzos de prevención, diagnóstico y tratamiento.

Históricamente, la personalización del tratamiento se ha confiado a la intuición y juicio clínico del profesional (Muela-Aparicio y Sansinenea-Méndez, 2020). Sin embargo, la evidencia acumulada sugiere que el juicio clínico aislado parece tener limitaciones intrínsecas por la influencia de heurísticos y sesgos. Por ejemplo, estudios clásicos y recientes demuestran que los terapeutas tienden a subestimar el deterioro de sus pacientes y a sobreestimar la probabilidad de mejora (Grove et al., 2000; Østergård et al., 2024). Además, un amplio cuerpo de estudios ha demostrado de manera consistente que los modelos estadísticos y predicciones de algoritmos a menudo superan a los juicios clínicos del profesional, particularmente entre profesionales con menos experiencia (Ægisdóttir et al., 2006; van Bronswijk et al., 2021). Un metaanálisis reciente realizado por Nye et al. (2023) reveló resultados superiores en las intervenciones personalizadas mediante algoritmos de precisión en comparación con las condiciones control y con los tratamientos estandarizados.

Dadas las limitaciones de la PBE y del juicio clínico, la Salud Mental de Precisión (SMP) emerge como una evolución y extensión lógica de los modelos tradicionales basados en la evidencia. El concepto de “precisión” se ha utilizado ampliamente en diversos ámbitos de la atención sanitaria, destacando la importancia de una comprensión integral de los factores biopsicosociales que influyen en el estado de salud de una persona. Si bien los enfoques basados en la precisión han constituido un elemento fundamental en la medicina durante décadas (por ejemplo, adaptación de tratamientos oncológicos en función de la genómica tumoral), su adopción en salud mental es relativamente reciente (Cohen y DeRubeis, 2018). Este enfoque se fundamenta en la pregunta seminal de Gordon Paul: “¿Qué tratamiento, por quién, es más

eficaz para este individuo con ese problema específico y bajo qué conjunto de circunstancias?” (Paul, 1969).

Componentes Fundamentales de la Salud Mental de Precisión

La SMP se fundamenta en dos pilares fundamentales: la evaluación rutinaria de resultados y procesos a lo largo del tratamiento y el uso de algoritmos para facilitar una toma de decisiones basada en datos (figura 1).

La Evaluación Como Brújula

En el paradigma de SMP, la evaluación deja de ser un trámite inicial para convertirse en una infraestructura continua, promoviendo un Cuidado Basado en la Medición (*Measurement-Based Care* – MBC, Bech, 2016). El MBC implica la evaluación sistemática de predictores biopsicosociales antes, durante y después del tratamiento, con el fin de monitorizar el progreso e informar la toma de decisiones clínicas. Diversos metaanálisis en distintas condiciones psicológicas y contextos asistenciales subrayan el impacto positivo de la MBC sobre los resultados del tratamiento y la adherencia, especialmente en pacientes con riesgo de fracaso terapéutico (por ejemplo, de Jong et al., 2021; Lutz et al., 2022). A diferencia de la práctica habitual, donde el progreso se evalúa subjetivamente (“¿Cómo te has sentido esta semana?”), el MBC proporciona unas métricas objetivas que permiten tres acciones fundamentales:

1. *Detección precoz*: cribado de pacientes que necesitan tratamiento o identificar pacientes que se desvían de la trayectoria esperada durante la intervención (i.e., estancamiento o deterioro que puede requerir pivotar en el tratamiento).
2. *Feedback del progreso*: el uso de gráficos visuales de progreso facilita que paciente y terapeuta discutan objetivos y expectativas con datos sobre la mesa, generando un lenguaje común y mejorando la motivación y adherencia terapéutica.

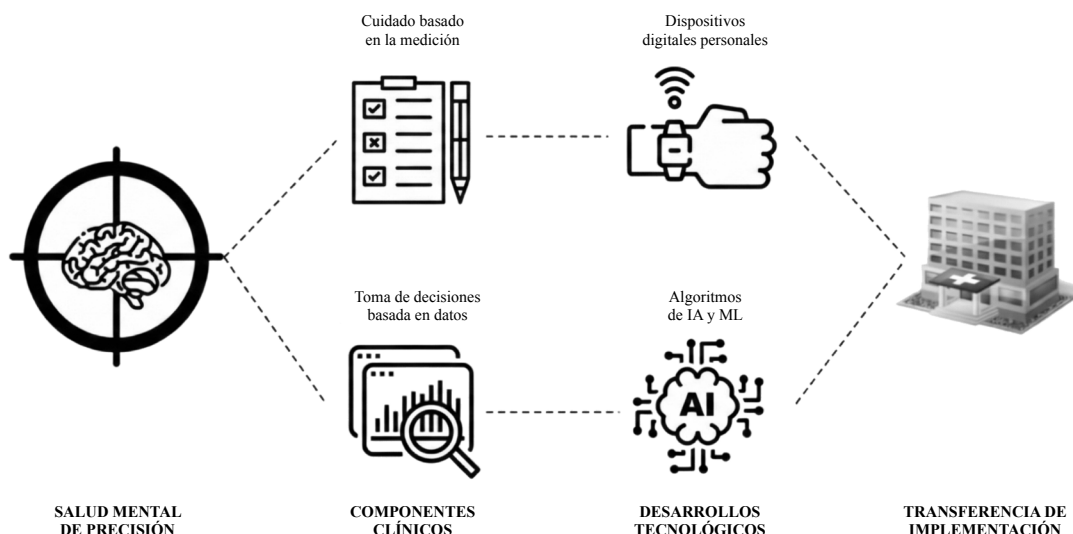
3. *Aprendizaje acumulativo*: agregar estos datos permite a los servicios de salud mental entender qué perfiles de pacientes responden mejor a qué tipos de terapia, creando una base de evidencia naturalista fundamental para alimentar algoritmos de IA. A nivel tecnológico, la omnipresencia de dispositivos digitales personales (como *smartphones* y *wearables*) ha simplificado la aplicación de Métodos de Muestreo de Experiencias (ESM) y la Evaluación Ecológica Momentánea (EMA), capturando datos longitudinales intensivos en tiempo real y facilitando la implementación del MBC en contextos reales (aan het Rot et al., 2012; Montag et al., 2020).

De los Datos a la Acción

Acumular datos no sirve de nada si no se usan para informar las acciones durante el tratamiento. Por tanto, el segundo pilar fundamental es el uso de modelos predictivos para transformar las mediciones en bruto en recomendaciones útiles para el proceso terapéutico. La evidencia meta-analítica sugiere resultados superiores en las intervenciones personalizadas mediante algoritmos de precisión en comparación con las condiciones control y con los tratamientos estandarizados (Nye et al., 2023). Esta metodología se conoce como Toma de Decisiones Informada por Datos (*Data-Informed Decision Making* – DIDM, Cohen et al., 2021), apoyando a las decisiones clínicas a múltiples niveles:

1. Antes del inicio del tratamiento, utilizando algoritmos para predecir el servicio y el profesional más adecuado para cada paciente (*matching* terapeuta-paciente).
2. Durante el tratamiento, informando sobre el curso de cada paciente e informando sobre la necesidad de terminar o pivotar la intervención en caso de que los resultados no sean los esperados.
3. Al finalizar el tratamiento, identificando riesgo de recaídas, necesidad de retomar la terapia y promoviendo modelos de prevención y promoción de la salud.

Figura 1
Marco Conceptual de la Salud Mental de Precisión (imagen de los autores)



Es fundamental destacar que, en este modelo, el profesional permanece como responsable de la toma de decisiones durante todo el proceso: el objetivo es transitar de una predicción clínica puramente intuitiva a una predicción “aumentada” basada en datos, donde el profesional cuenta con recomendaciones de algoritmos de predicción para mejorar el proceso terapéutico. A nivel tecnológico, la DIDM ha experimentado un crecimiento exponencial en los últimos años gracias a la popularidad de las técnicas de Inteligencia Artificial (IA) y *Machine Learning* (ML) (Roca, 2025).

Del Laboratorio a la Consulta: el Reto de la Implementación

Dados los beneficios y ventajas de los componentes que conforman el paradigma de SMP, tanto la *American Psychological Association* (APA) como la *Roadmap for Mental Health Research in Europe* han abogado por la integración de tecnologías de SMP en la práctica clínica habitual (APA, 2017; Wright et al., 2020). Existen algunos ejemplos pioneros de iniciativas que tratan de implementar los principios de SMP en contextos reales, como el programa IAPT (ahora *NHS Talking Therapies*) en el Reino Unido (Wakefield et al., 2021), donde la monitorización rutinaria de resultados y el apoyo algorítmico ya se utilizan para guiar decisiones en sistemas de salud a gran escala.

Un enfoque prometedor para facilitar la adopción de la SMP en contextos ambulatorios es el uso de los denominados Sistemas de Apoyo a la Decisión Clínica (*Clinical Decision Support Systems – CDSS*, Schaffrath et al., 2022): sistemas de software integrados en la historia clínica electrónica o como plataformas independientes diseñados para ayudar a los profesionales a aplicar prácticas basadas en la medición y orientadas por datos para apoyar el diagnóstico y la personalización del tratamiento. Los CDSS convierten los “ingredientes” del paradigma de SMP en ayudas visuales digeribles: cuadros de mando, *feedback* visual, alertas de riesgo o sugerencias textuales. Existen varios ejemplos de CDSS en medicina, donde ayudan a los médicos a decidir la mejor alternativa terapéutica incorporando la evidencia empírica más reciente disponible junto con los valores y preferencias de los pacientes (Harrison et al., 2020). En cambio, su aplicación en psicología sigue siendo bastante limitada a pesar de que la evidencia científica sugiere que su uso se asocia con aumentos en el tamaño del efecto de las intervenciones en comparación con el tratamiento habitual (Lutz et al., 2022). Un ejemplo destacado de CDSS en psicología es el Trier Treatment Navigator (TTN; Lutz et al., 2019), un software que proporciona

recomendaciones de tratamiento individualizadas e informadas por datos, así como ajustes basados en la monitorización continua de resultados durante el tratamiento. En España, plataformas como *Psypilot* (Roca et al., 2026) están comenzando a traducir estas ideas en soluciones escalables aprovechando la IA para potenciar la implementación mediante un asistente virtual que interpreta las recomendaciones mediante modelos de lenguaje, actuando así como un verdadero “copiloto” para el profesional.

A pesar de estos esfuerzos, la implementación del paradigma de SMP en la práctica clínica ha sido muy limitada, lo que ha generado una brecha entre los avances científicos y la atención en salud mental que se presta en entornos reales. Por ejemplo, un estudio reciente encontró que tan solo el 14% de los profesionales utiliza medidas rutinarias del progreso de sus pacientes (Jensen-Doss et al., 2018) y menos del 1% de los modelos predictivos desarrollados en investigación llegan a probarse en entornos clínicos reales (Salazar de Pablo et al., 2021). La adopción de la SMP requiere superar una serie de barreras de implementación que están resumidos en el marco *Implementing Precision Method* (IPM; Deisenhofer et al., 2024), que clasifica estas barreras en cuatro dominios críticos que deben abordarse para una adopción exitosa (tabla 1).

Introducción al Proyecto NOVA

En este escenario nace el proyecto NOVA (*Navigating Outcomes via Analytics*), con el compromiso de investigar cómo implementar la SMP en la compleja realidad de la práctica psicológica cotidiana. El proyecto se aleja de la validación teórica de algoritmos para centrarse en un enfoque traslacional, diseñado en torno al marco IPM para anticipar y resolver barreras de implementación. El proyecto NOVA no se limita a adoptar nuevas medidas, sino que busca integrar todo el flujo de trabajo de precisión en los servicios de atención a la salud mental (desde la recogida de datos hasta el soporte a la decisión). Para ello, el proyecto despliega una estrategia en varias fases que dan respuesta a las cuatro dimensiones del marco IPM:

1. *Investigación actitudinal*: mapear las actitudes, beneficios percibidos y preocupaciones de los profesionales en salud mental para informar cómo deben diseñarse e implementarse las tecnologías de precisión.
2. *Ensayos clínicos pragmáticos en contextos reales*: evaluar no solo los resultados de los pacientes tras el uso de tecnologías SMP, sino también la usabilidad, el ajuste al flujo de trabajo y el impacto en los procesos terapéuticos.

Tabla 1
Barreras de Implementación de Tecnologías de Salud Mental de Precisión en Contextos Reales

Actitudinal (fase 1)	<ul style="list-style-type: none"> • Necesidades de los interesados • Preocupaciones de los interesados • Capacitación de los interesados 	La principal barrera suele ser humana, no técnica; la percepción de una pérdida de autonomía, el miedo a dañar la alianza terapéutica o la carga de trabajo adicional son determinantes. Si la/el profesional no percibe un valor clínico claro (por ejemplo, reducir abandonos), la adherencia de las tecnologías SMP será baja.
Tecnológica (fase 2)	<ul style="list-style-type: none"> • Software y hardware • Usabilidad e interfaz de usuario • Sistema de Soporte a la Decisión Clínica 	La falta de infraestructura segura, la interoperabilidad con las historias clínicas electrónicas y la usabilidad del software (“experiencia de usuario”) son cuellos de botella frecuentes.
Estadística (fase 3)	<ul style="list-style-type: none"> • Evaluación y utilidad del modelo • Generalización a diferentes poblaciones • Deriva del modelo a lo largo del tiempo 	Los clínicos necesitan confiar en la “caja negra”; problemas como el sobreajuste de los modelos, el sesgo algorítmico (funcionar peor en ciertas minorías) o la falta de transparencia minan la confianza ética necesaria para su uso.
Contextual (fase 4)	<ul style="list-style-type: none"> • Social y financiero • Legal y ético • Laboratorio vs. mundo real 	Las políticas del servicio, la cultura organizacional y los modelos de reembolso pueden facilitar u obstaculizar la adopción de tecnologías SMP, relegando estas herramientas a meros proyectos piloto sin continuidad.

3. *Desarrollo de nuevos algoritmos de predicción*: aprovechando los datos recopilados en fases previas, desarrollaremos modelos de IA y ML robustos e interpretables que puedan ser auditados, centrados en el emparejamiento de pacientes y profesionales para optimizar el vínculo terapéutico.
4. *Política y diseminación*: conectar los hallazgos con las estrategias nacionales de salud mental y digital para promover la transferencia científica y la adopción de tecnologías SMP en sistemas públicos y privados.

Más allá de la ejecución inmediata de sus fases, se prevé que el proyecto NOVA entregue un conjunto de productos tangibles e infraestructuras que trasciendan el marco temporal del proyecto, asegurando su sostenibilidad a largo plazo:

Infraestructura de Datos y Medición Estandarizada

Establecimiento de una arquitectura robusta para la SMP en los servicios de salud mental. Esto incluye la implementación de baterías de evaluación validadas, la digitalización de flujos de trabajo y la creación de pipelines de datos interoperables que faciliten el flujo de información entre sistemas.

Bases de Datos Curadas Para la Investigación

Generación de *datasets* depurados y listos para la investigación continua. Estos datos serán fundamentales para el desarrollo de futuros modelos pronósticos, estudios sobre personalización del tratamiento e investigación sobre los efectos del terapeuta, contribuyendo así a los esfuerzos internacionales para refinar metodologías en este campo.

Prototipos Funcionales de CDSS

Desarrollo de prototipos operativos de algoritmos y Sistemas de Soporte a la Decisión, co-diseñados junto a profesionales y pacientes. Estos prototipos estarán preparados para su posterior escalado o integración directa en plataformas de gestión clínica ya existentes.

Capital Humano y Competencias

La formación de una comunidad de profesionales capacitados en las competencias específicas de la SMP. Este es un ingrediente indispensable para la emergencia y consolidación del perfil del “psicólogo de precisión” en los sistemas sanitarios.

Recomendaciones Políticas y Estratégicas

Elaboración de guías sobre facilitadores y barreras para la implementación de la SMP, conectadas directamente con las estrategias nacionales de salud mental en curso, sirviendo de brújula para el diseño de políticas públicas.

Conclusión

La Salud Mental de Precisión se propone como una extensión metodológica necesaria para superar las barreras de los métodos tradicionales, operacionalizando la personalización del tratamiento a través del Cuidado Basado en la Medición y la Toma de Decisiones Basada en Datos.

No obstante, la disponibilidad de tecnologías y algoritmos de precisión no garantiza su adopción en contextos reales. En este contexto, el proyecto NOVA aporta un enfoque traslacional, desplazando el foco de la mera validación hacia la ciencia de la implementación.

Al abordar sistemáticamente los dominios actitudinales, tecnológicos, estadísticos y contextuales, el proyecto NOVA aspira a establecer una infraestructura empírica que permita validar si la integración de Sistemas de Soporte a las Decisiones Clínicas para mejorar el resultado de los tratamientos psicológicos y reducir las tasas de abandono.

En definitiva, este trabajo plantea que la modernización de las intervenciones en salud mental no depende únicamente de la innovación tecnológica, sino de la capacidad para integrar dichas herramientas en el flujo de trabajo del profesional de manera sostenible. Los resultados derivados del proyecto NOVA pretenden ofrecer la evidencia necesaria para transitar de una predicción teórica a una optimización real y cuantificable de la atención psicológica.

Contribución a la Autoría

Pablo Roca y Sara Rodríguez Moreno redactaron el manuscrito.

Todos los demás autores contribuyeron a la conceptualización del proyecto y también a la revisión, edición y formato final del artículo.

Conflicto de Intereses

Alguno de los autores colabora con una empresa que desarrolla soluciones tecnológicas en psicología, sin que ello suponga menoscabo de su plena independencia científica.

Financiación

Este estudio está financiado por el proyecto PID2024-156740OA-I00 financiado por MICIU/AEI/10.13039/501100011033 y por FEDER, UE.

Referencias

- aan het Rot, Marije; Hogenelst, Koen y Schoevers, Robert A. (2012). Mood disorders in everyday life: A systematic review of experience sampling and ecological momentary assessment studies. *Clinical Psychology Review*, 32(6), 510–523. <https://doi.org/10.1016/j.cpr.2012.05.007>
- Ægisdóttir, Stefánía; White, Michael J.; Spengler, Paul M.; Maugherman, Alan S.; Anderson, Linda A.; Cook, Robert S.; Nichols, Cassandra N.; Lampropoulos, Georgios K.; Walker, Blain S.; Cohen, Genna y Rush, Jeffrey D. (2006). The meta-analysis of Clinical Judgment Project: Fifty-six years of accumulated research on clinical versus statistical prediction. *The Counseling Psychologist*, 34(3), 341–382. <https://doi.org/10.1177/0011000005285875>
- American Psychological Association. (2017). *Clinical practice guideline for the treatment of depression across three age cohorts*. <https://www.apa.org/depression-guideline>
- Bech, Per (2016). *Measurement-based care in mental disorders*. Springer. <https://doi.org/10.1007/978-3-319-46651-4>

- Cohen, Zachary D.; Delgadillo, Jaime y DeRubeis, Robert J. (2021). Personalized treatment approaches. En Michael Barkham, Wolfgang Lutz y Louis G. Castonguay (Eds.), *Bergin and Garfield's handbook of psychotherapy and behavior change, 7th Ed.* (pp. 673–704). Wiley.
- Cohen, Zachary D. y DeRubeis, Robert J. (2018). Treatment selection in depression. *Annual Review of Clinical Psychology, 14*, 209–236. <https://doi.org/10.1146/annurev-clinpsy-050817-084746>
- Cooper, Andrew A. y Conklin, Laren R. (2015). Dropout from individual psychotherapy for major depression: A meta-analysis of randomized clinical trials. *Clinical Psychology Review, 40*, 57–65. <https://doi.org/10.1016/j.cpr.2015.05.001>
- Cuijpers, Pim; Quero, Soledad; Noma, Hisashi; Ciharova, Marketa; Miguel, Clara; Karyotaki, Eirini; Cipriani, Andrea; Cristea, Ionana A. y Furukawa, Toshi A. (2021). Psychotherapies for depression: A network meta-analysis covering efficacy, acceptability and long-term outcomes of all main treatment types. *World Psychiatry - Official Journal of the World Psychiatric Association (WPA), 20*(2), 283–293. <https://doi.org/10.1002/wps.20860>
- de Jong, Kim; Conijn, Judith M.; Gallagher, Roisin A.V.; Reshetnikova, Alexandra S.; Heij, Marya y Lutz, Miranda C. (2021). Using progress feedback to improve outcomes and reduce drop-out, treatment duration, and deterioration: A multilevel meta-analysis. *Clinical Psychology Review, 85*, 102002. <https://doi.org/10.1016/j.cpr.2021.102002>
- Deisenhofer, Anne-Katharina; Barkham, Michael; Beierl, Esther T.; Schwartz, Brian; Aafjes-van Doorn, Katie; Beevers, Christopher G.; Berwian, Isabel M.; Blackwell, Simon E.; Bockting, Claudi L.; Brakemeier, Eva-Lotta; Brown, Gary; Buckman, Joshua E.J.; Castonguay, Louis G.; Cusack, Claire E.; Dalgleish, Tim; de Jong, Kim; Delgadillo, Jaime; DeRubeis, Robert J.; Driessen, Ellen; Ehrenreich-May, Jill; Fisher, Aaron J.; Fried, Eiko I.; Fritz, Jessica; Furukawa, Toshi A.; Gillan, Claire M.; Gómez Penedo, Juan Martín; Hitchcock, Peter F.; Hofmann, Stefan G.; Hollon, Steven D.; Jacobson, Nicholas C.; Karlin, Daniel R.; Lee, Chi Tak; Levinson, Cheri A.; Lorenzo-Luaces, Lorenzo; McDanal, Riley; Moggia, Danilo; Ng, Mei Yi; Norris, Lesley A.; Patel, Vikram; Piccirillo, Marilyn L.; Pilling, Stephen; Rubel, Julian A.; Salazar-de-Pablo, Gonzalo; Saunders, Rob; Schleider, Jessica L.; Schnurr, Paula P.; Schueller, Stephen M.; Siegle, Greg J.; Uher, Rudolf; Watkins, Ed; Webb, Christian A.; Wiltsey Stirman, Shannon; Wynants, Laure; Youn, Soo Jeong; Zilcha-Mano, Sigal; Lutz, Wolfgang y Cohen, Zachary D. (2024). Implementing precision methods in personalizing psychological therapies: Barriers and possible ways forward. *Behaviour Research and Therapy, 172*, 104443. <https://doi.org/10.1016/j.brat.2023.104443>
- DeRubeis, Robert J.; Cohen, Zachary D.; Forand, Nicholas R.; Fournier, Jay C.; Gelfand, Lois A. y Lorenzo-Luaces, Lorenzo (2014). The Personalized Advantage Index: Translating research on prediction into individualized treatment recommendations. A demonstration. *PLoS ONE, 9*(1), e83875. <https://doi.org/10.1371/journal.pone.0083875>
- Grove, William M.; Zald, David H.; Lebow, Boyd S.; Snitz, Beth E. y Nelson, Chad (2000). Clinical versus mechanical prediction: a meta-analysis. *Psychological Assessment, 12*(1), 19–30. <https://doi.org/10.1037/1040-3590.12.1.19>
- Harrison, Philippa.; Carr, Ewan; Goldsmith, Kimberley; Young, Allan H.; Ashworth, Mark; Fennema, Diede; Barrett, Barbara y Zahn, Roland (2020). Study protocol for the antidepressant advisor (ADeSS): A decision support system for antidepressant treatment for depression in UK primary care: A feasibility study. *BMJ Open, 10*, e035905. <https://doi.org/10.1136/bmjopen-2019-035905>
- Jensen-Doss, Amanda; Becker-Haimes, Emily M.; Smith, Ashley M.; Lyon, Aaron R.; Lewis, Cara C.; Stanick, Cameo F. y Hawley, Krintin M. (2018). Monitoring treatment progress and providing feedback is viewed favorably but rarely used in practice. *Administration and Policy in Mental Health, 45*(1), 48–61. <https://doi.org/10.1007/s10488-016-0763-0>
- Lutz, Wolfgang; Rubel, Julian A.; Schwartz, Brian; Schilling, Viola y Deisenhofer, Anna-Katherina (2019). Towards integrating personalized feedback research into clinical practice: Development of the Trier Treatment Navigator (TTN). *Behaviour Research and Therapy, 120*, 103438. <https://doi.org/10.1016/j.brat.2019.103438>
- Lutz, Wolfgang; Schwartz, Brian y Delgadillo, Jaime (2022). Measurement-based and data-informed psychological therapy. *Annual Review of Clinical Psychology, 18*(1), 71–98. <https://doi.org/10.1146/annurev-clinpsy-071720-014821>
- Montag, Chrintian; Sindermann, Cornalia y Baumeister, Harald (2020). Digital phenotyping in psychological and medical sciences: A reflection about necessary prerequisites to reduce harm and increase benefits. *Current Opinion in Psychology, 36*, 19–24. <https://doi.org/10.1016/j.copsyc.2020.03.013>
- Muela-Aparicio, Alexander y Sansinenea-Méndez, Eneko (2020). Tratamientos psicológicos personalizados: orientaciones clínicas. *Papeles del Psicólogo, 41*(1), 16–26. <https://doi.org/10.23923/pap.psicol2020.2915>
- Nye, Arthur; Delgadillo, Jaime y Barkham, Michael (2023). Efficacy of personalized psychological interventions: A systematic review and meta-analysis. *Journal of Consulting and Clinical Psychology, 91*(7), 389–397. <https://doi.org/10.1037/ccp0000820>
- Ormel, Johan; Hollon, Steven D.; Kessler, Ronald C.; Cuijpers, Pim y Monroe, Scott M. (2022). More treatment but no less depression: The treatment-prevalence paradox. *Clinical Psychology Review, 91*, 102111. <https://doi.org/10.1016/j.cpr.2021.102111>
- Østergård, Ole K.; Grønnebak, Lasse y Nilsson, Kristine. K. (2024). Do therapists know when their clients deteriorate? An investigation of therapists' ability to estimate and predict client change during and after psychotherapy. *Clinical Psychology & Psychotherapy, 31*(6). <https://doi.org/10.1002/cpp.70015>
- Paul, Gordon L. (1969). Behavior modification research: Design and tactics. En: Cyril M. Franks (Ed.), *Behavior Therapy: Appraisal and Status* (pp. 29–62). McGraw-Hill.
- Purgato, Marianna; Singh, Rakesh; Acarturk, Cere,m y Cuijpers, Pim (2021). Moving beyond a 'one-size-fits-all' rationale in global mental health: Prospects of a precision psychology paradigm. *Epidemiology and Psychiatric Sciences, 30*, e63. <https://doi.org/10.1017/S2045796021000500>
- Roca, Pablo (2025). ¿Puede una mente artificial sanar una mente natural? Aplicaciones de la inteligencia artificial en psicología. En José M. Ortiz-Ibarz y Jaime Benguría-Aguirreche (Coords.), *Un nuevo conocimiento transversal: la inteligencia artificial aplicada* (pp. 145–165). Tirant lo Blanch.
- Roca, Pablo; Zangri, Rosaria M.; Rodríguez-Fernández, Guillermo; Sánchez-Pedreño, Martín y García del Valle, Eduardo P. (2026). Artificial intelligence in the psychologist's toolkit: Psypilot as a case study. *Frontiers in Psychology, 17*, 1775464. <https://doi.org/10.3389/fpsyg.2026.1775464>
- Roos, Johanna y Werbart, Andrzej (2013). Therapist and relationship factors influencing dropout from individual psychotherapy: a literature review. *Psychotherapy Research: Journal of the Society for*

- Psychotherapy Research*, 23(4), 394–418. <https://doi.org/10.1080/10503307.2013.775528>
- Salazar de Pablo, Gonzalo; Studerus, Erich; Vaquerizo-Serrano, Julio; Irving, Jessica; Catalán, Ana; Oliver, Dominic; Baldwin, Helen; Danese, Andrea; Fazel, Seena; Steyerberg, Ewout W, Stahl, Daniel y Fusar-Poli, Paolo (2021). Implementing precision psychiatry: A systematic review of individualized prediction models for clinical practice. *Schizophrenia Bulletin*, 47(2), 284–297. <https://doi.org/10.1093/schbul/sbaa120>
- Schaffrath, Jana; Weinmann-Lutz, Birgit y Lutz, Wolfgang (2022). The Trier Treatment Navigator (TTN) in action: Clinical case study on data-informed psychological therapy. *Journal of Clinical Psychology*, 78(10), 2016–2028. <https://doi.org/10.1002/jclp.23362>
- Schwartz, Brian; Cohen, Zachary D.; Rubel, Julian A.; Zimmermann, Dirk; Wittmann, Werner W. y Lutz, Wolfgang (2021). Personalized treatment selection in routine care: Integrating machine learning and statistical algorithms to recommend cognitive behavioral or psychodynamic therapy. *Psychotherapy Research*, 31(1), 33–51. <https://doi.org/10.1080/10503307.2020.1769219>
- van Bronswijk, Suzanne C.; Lemmens, Lotte H.; Huibers, Markus J. y Peeters, Frenk P. (2021). Selecting the optimal treatment for a depressed individual: Clinical judgment or statistical prediction? *Journal of Affective Disorders*, 279, 149–157. <https://doi.org/10.1016/j.jad.2020.09.135>
- Wakefield, Sara; Kellett, Stephen; Simmonds-Buckley, Melanie; Stockton, Daniel; Bradbury, Abigail y Delgadillo, Jaime (2021). Improving Access to Psychological Therapies (IAPT) in the United Kingdom: A systematic review and meta-analysis of 10-years of practice-based evidence. *British Journal of Clinical Psychology*, 60(1), 1–37. <https://doi.org/10.1111/bjc.12259>
- Weisz, John. R.; Kuppens, Sophie; Ng, Mei Yi; Vaughn-Coaxum, Rachel A.; Ugueto, Ana M.; Eckshtain, Dikla y Corteselli, Katherine A. (2019). Are psychotherapies for young people growing stronger? Tracking trends over time for youth anxiety, depression, attention-deficit/hyperactivity disorder, and conduct problems. *Perspectives on Psychological Science*, 14(2), 216–237. <https://doi.org/10.1177/1745691618805436>
- Wright, Caroline V.; Goodheart, Carol; Bard, David; Bobbitt, Bruce L.; Butt, Zeeshan; Lysell, Kathleen; McKay, Dean y Stephens, Kari (2020). Promoting measurement-based care and quality measure development: The APA mental and behavioral health registry initiative. *Psychological Services*, 17(3), 262–270. <https://doi.org/10.1037/ser0000347>

