

[ r e v i s i ó n ]

# Aplicaciones de inteligencia artificial y e-health en el manejo nutricional de las personas con diabetes

## *Applications of artificial intelligence and e-health in the nutritional management of diabetes*

Ana Zugasti Murillo<sup>1</sup> y Alejandro Sanz París<sup>2</sup>

<sup>1</sup>Sección de Nutrición. Hospital Universitario de Navarra. Pamplona (Navarra). España. <sup>2</sup>Servicio de Endocrinología y Nutrición, Hospital Miguel Servet. Zaragoza. España.

### Cómo citar este trabajo

Zugasti Murillo A, Sanz París A. Aplicaciones de la inteligencia artificial y e-health en el manejo nutricional de las personas con diabetes. Nutr Clin Med 2026;20(1):39-53

## >>RESUMEN

### Palabras clave

Diabetes *mellitus*, inteligencia artificial, medicina de precisión, monitorización continua de glucosa, terapia nutricional.

El manejo nutricional de la diabetes *mellitus* constituye uno de los pilares fundamentales del tratamiento, pero también uno de los componentes más complejos del autocuidado, debido a la elevada carga cognitiva asociada al recuento manual de hidratos de carbono y a la variabilidad interindividual de la respuesta glucémica. En los últimos años, la integración de la inteligencia artificial junto con la monitorización continua de glucosa y otros dispositivos digitales ha impulsado una transición hacia un modelo de nutrición de precisión, basado en el análisis en tiempo real de datos fisiológicos, dietéticos y conductuales.

Las herramientas basadas en inteligencia artificial permiten automatizar el registro dietético, estimar la composición nutricional de los alimentos, predecir la respuesta glucémica posprandial y generar recomendaciones personalizadas. Además, contribuyen a reducir la carga cognitiva del paciente, favoreciendo la adherencia terapéutica y mejorando potencialmente el control glucémico. Aunque los estudios disponibles sugieren mejoras modestas, pero clínicamente relevantes en parámetros como la glucemia posprandial y el tiempo en rango, persisten limitaciones importantes relacionadas con la validación a largo plazo, la generalización en poblaciones diversas y la transparencia algorítmica.

### Correspondencia

????????????????????????????????????  
Email: ????????????????????????????????

Obra bajo Licencia Creative Commons Reconocimiento-  
NoComercial-CompartirIgual 4.0 Internacional.  
Más información:  
<http://creativecommons.org/licenses/by-nc-sa/4.0/>



Esta revisión analiza de forma integrativa el ecosistema actual de aplicaciones de inteligencia artificial en el manejo nutricional de la diabetes *mellitus*, evaluando su fundamento tecnológico, la evidencia clínica disponible y sus principales limitaciones. Asimismo, se abordan aspectos emergentes como la nutrición de precisión avanzada, el papel del microbioma, la perspectiva de género, la equidad digital y los retos regulatorios. La inteligencia artificial debe entenderse como una herramienta de apoyo que complementa, pero no sustituye, el juicio clínico, requiriendo una integración crítica en la práctica asistencial.

*Nutr Clin Med* 2026; 20 (1): 39-53  
DOI: 10.7400/NCM.2026.20.1.0020

### Key words

Diabetes mellitus, artificial intelligence, diet therapy, continuous glucose monitoring, precision medicine.

### <<ABSTRACT

Nutritional management is a cornerstone of diabetes mellitus (DM) treatment, yet it remains one of the most complex components of self-care due to the high cognitive burden associated with manual carbohydrate counting and the marked interindividual variability in glycemic response. In recent years, the integration of artificial intelligence (AI), continuous glucose monitoring, and other digital health technologies have driven a shift toward a precision

nutrition model based on real-time analysis of physiological, dietary, and behavioral data.

AI-based tools enable automated dietary logging, estimation of food composition, prediction of postprandial glycemic responses, and generation of personalized nutritional recommendations. Additionally, these technologies may reduce patient cognitive burden, potentially improving treatment adherence and glycemic control. Although current evidence suggests modest but clinically meaningful improvements in outcomes such as postprandial glucose and time in range, important limitations persist, including the need for long-term validation, broader population generalizability, and greater algorithmic transparency.

This integrative review examines the current landscape of AI applications in nutritional management of DM, assessing their technological foundations, available clinical evidence, and key limitations. It also addresses emerging areas such as advanced precision nutrition, the role of microbiome, gender-related aspects, digital equity, and regulatory challenges. AI should therefore be regarded as a supportive tool that complements, rather than replaces, clinical judgment, requiring careful integration into routine clinical practice.

*Nutr Clin Med* 2026; 20 (1): 39-53  
DOI: 10.7400/NCM.2026.20.1.0020

### >>INTRODUCCIÓN: CAMBIO DE PARADIGMA EN EL TRATAMIENTO NUTRICIONAL DE LA DIABETES

Durante décadas, el tratamiento nutricional de la diabetes *mellitus* (DM) se ha basado en un modelo educativo esencialmente estático, centrado en guías dietéticas poblacionales y en la capacitación del paciente para el cálculo manual de hidratos de carbono y los ajustes terapéuticos. Este enfoque, eficaz en contextos altamente estructurados, ha mostrado limitaciones relevantes en la práctica clínica, donde la variabilidad individual, cultural y conductual condiciona de forma decisiva el control metabólico.

Entre 2020 y 2025, la integración de la inteligencia artificial (IA) en el manejo de la DM ha catalizado un cambio hacia un modelo de nutrición de precisión, en el que grandes volúmenes de datos fisiológicos y conductuales pueden ser analizados en tiempo real. La combinación de monitorización continua de glucosa (MCG), registros dietéticos digitalizados, sensores de actividad y algoritmos de aprendizaje automático ha permitido pasar de una visión retrospectiva del control glucémico a una aproximación predictiva y personalizada<sup>1,2</sup>.

En este nuevo paradigma, la IA actúa como un “copiloto cognitivo”, capaz de identificar patrones que escapan a la percepción humana y de

contextualizar la ingesta alimentaria dentro del estado metabólico dinámico del paciente. No obstante, este avance tecnológico plantea interrogantes clínicos relevantes sobre su precisión, su impacto real en resultados en salud y su integración ética y segura en la práctica asistencial.

El objetivo de esta revisión es analizar de forma crítica el papel de la IA en el manejo nutricional de la persona con DM, evaluando sus aplicaciones actuales, la evidencia clínica disponible, sus limitaciones y las implicaciones para la práctica asistencial.

>>EVOLUCIÓN DEL AUTOCUIDADO NUTRICIONAL Y REDUCCIÓN DE LA CARGA COGNITIVA

El autocuidado nutricional constituye uno de los componentes más complejos del manejo de la DM, particularmente en personas con diabetes tipo 1 y en aquellas con diabetes tipo 2 en tratamiento con insulina. El recuento manual de hidratos de carbono implica no solo conocimientos nutricionales, sino también habilidades de estimación de porciones y una atención sostenida en cada ingesta, lo que conlleva una elevada carga cognitiva y una mayor probabilidad de error. Diversos estudios observacionales han mostrado que una proporción sustancial de las ingestas es subestimada, lo que contribuye a una mayor variabilidad glucémica posprandial<sup>3</sup>.

En este contexto, las herramientas basadas en IA han emergido con el objetivo de automatizar y simplificar el registro dietético mediante técnicas de visión computacional, reconocimiento de imágenes y procesamiento del lenguaje natural. Más allá de mejorar la precisión del recuento de hidratos de carbono, estas soluciones buscan reducir el esfuerzo mental asociado al proceso de toma de decisiones alimentarias, facilitando un modelo de autocuidado más sostenible en el tiempo. Este cambio desplaza el foco desde un enfoque centrado en el cálculo manual hacia un sistema de apoyo continuo y contextualizado en tiempo real (tabla I).

Desde una perspectiva clínica, la reducción de la carga cognitiva tiene implicaciones relevantes. El esfuerzo sostenido requerido para el manejo dietético se ha asociado con fatiga decisional, menor adherencia terapéutica y peor control glucémico. Estudios cualitativos han identificado el estrés relacionado con la alimentación como una de las principales barreras para el autocuidado efectivo, especialmente en mujeres y en pacientes con múltiples demandas familiares o laborales<sup>4</sup>.

>>ECOSISTEMA TECNOLÓGICO ACTUAL: MONITORIZACIÓN CONTINUA DE GLUCOSA, WEARABLES Y DATOS MULTIMODALES

La expansión de la IA en el ámbito de la nutrición aplicada a la DM está estrechamente vinculada al


| TABLA I. EVOLUCIÓN DEL MODELO DE MANEJO NUTRICIONAL EN LA DIABETES MELLITUS: DEL ENFOQUE CONVENCIONAL A LA INTEGRACIÓN CON INTELIGENCIA ARTIFICIAL |                                                                     |                                                                                  |
|----------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------|----------------------------------------------------------------------------------|
| Evolución del modelo nutricional                                                                                                                   | Modelo convencional                                                 | Modelo basado en inteligencia artificial                                         |
| Metodología de registro                                                                                                                            | Diarios de papel o registros manuales en aplicaciones.              | Captura fotográfica, escaneo de códigos de barras y sensores de movimiento.      |
| Análisis de datos                                                                                                                                  | Revisión periódica (mensual/ trimestral) por el profesional.        | Procesamiento en tiempo real con <i>feedback</i> instantáneo al paciente         |
| Precisión del recuento                                                                                                                             | Alta dependencia del entrenamiento y estado cognitivo del paciente. | Automatización mediante visión computacional con errores inferiores al 15 %.     |
| Base de recomendación                                                                                                                              | Guías nutricionales poblacionales (“talla única”).                  | Nutrición de precisión basada en el microbioma y respuesta glucémica individual. |
| Intervención                                                                                                                                       | Reactiva a los niveles de glucosa ya alterados.                     | Predictiva, sugiriendo ajustes antes de la ingesta o el ejercicio.               |

desarrollo y la adopción generalizada de dispositivos de MCG. Entre 2020 y 2025, estos dispositivos se han consolidado como el estándar de referencia para la evaluación dinámica del control glucémico, al proporcionar series temporales de alta resolución que permiten caracterizar con mayor precisión la relación entre la ingesta alimentaria y la respuesta glucémica.

A estos datos se suman los procedentes de dispositivos portátiles, como relojes inteligentes y bandas de actividad, que aportan información relevante sobre variables fisiológicas y conductuales, incluyendo niveles de actividad física, gasto energético estimado, frecuencia cardíaca y parámetros relacionados con el sueño. La integración de estos flujos de datos heterogéneos, conocida como análisis multimodal, constituye la base sobre la que operan los modelos predictivos actuales, permitiendo contextualizar la respuesta metabólica más allá de la composición de la dieta e incorporando factores como el estado de actividad, el ritmo circadiano o la calidad del descanso<sup>5</sup>.

Este enfoque representa un cambio sustancial respecto a modelos previos centrados exclusivamente en la ingesta, al posibilitar recomendaciones nutricionales adaptadas al estado fisiológico dinámico del individuo. Desde una perspectiva clínica, esta capacidad de contextualización resulta especialmente relevante en situaciones de alta variabilidad glucémica, como la práctica de ejercicio físico o las alteraciones del sueño.

De forma emergente, se están desarrollando biosensores no invasivos orientados a la monitorización de parámetros adicionales, como cetonas o lactato, así como estimaciones indirectas de composición corporal. Aunque su integración en la práctica clínica es todavía limitada, estos avances podrían ampliar el alcance de la nutrición de precisión, particularmente en contextos como el tratamiento con agonistas del receptor del péptido glucagonoide de tipo 1, donde la preservación de la masa magra constituye un objetivo relevante del manejo nutricional<sup>6</sup>.



Este ecosistema tecnológico constituye el sustrato sobre el que se desarrollan las aplicaciones específicas de IA descritas en el siguiente epígrafe.

## >> APLICACIONES ACTUALES DE LA INTELIGENCIA ARTIFICIAL EN EL MANEJO NUTRICIONAL DE LA DIABETES

### Reconocimiento automático de alimentos y estimación nutricional

La visión computacional representa la aplicación más madura de la IA en el ámbito nutricional. Herramientas como LogMeal® o goFOOD® utilizan redes neuronales convolucionales entrenadas con grandes bases de datos de imágenes para identificar alimentos, segmentar porciones y estimar su contenido nutricional.

Un estudio coreano sobre FoodLens demostró que esta tecnología, integrada en una plataforma de salud digital con MCG, produjo reducciones significativas de la hemoglobina glucosilada (HbA1c) (0,6-0,9 %) y pérdida de peso en pacientes con diabetes tipo 2 durante 48 semanas, superando incluso al cuidado rutinario cuando se acompañaba de retroalimentación clínica personalizada<sup>7</sup>.

Diversos estudios de validación y revisiones sistemáticas han puesto de manifiesto una amplia variabilidad en la precisión de los sistemas de reconocimiento automático de alimentos, con resultados que dependen en gran medida del tipo de alimento, la complejidad del plato y las condiciones de captura de la imagen. En general, los mejores resultados se observan en alimentos preenvasados o de estructura simple, mientras que los platos mixtos o de elaboración casera presentan mayores tasas de error<sup>8-10</sup>.

### Modelos de lenguaje y planificación nutricional personalizada

Los modelos de lenguaje de gran escala (LLM, del inglés *large language models*), como ChatGPT o Gemini, están emergiendo como herramientas potenciales para la generación de recomendaciones nutricionales personalizadas basadas en lenguaje natural. Su capacidad para integrar información clínica, preferencias dietéticas y patrones culturales los posiciona como sistemas

prometedores de apoyo en la planificación alimentaria.

En los últimos años, se han propuesto marcos que combinan LLM con técnicas de *retrieval-augmented generation* (RAG) y aprendizaje federado con el objetivo de mejorar la precisión, la trazabilidad de las recomendaciones y la protección de los datos.

Los LLM son modelos de IA entrenados con grandes volúmenes de texto capaces de comprender y generar lenguaje natural, lo que permite desarrollar sistemas conversacionales, asistentes clínicos o herramientas de apoyo a la toma de decisiones. En el ámbito sanitario, pueden utilizarse para interpretar registros clínicos, responder preguntas médicas o generar recomendaciones nutricionales personalizadas.

Las técnicas RAG combinan la capacidad generativa de los LLM con sistemas de recuperación de información externos. En lugar de basarse únicamente en el conocimiento incluido durante el entrenamiento del modelo, el sistema consulta bases de datos, guías o historias clínicas relevantes en tiempo real antes de generar la respuesta. Esto mejora la actualización, precisión y trazabilidad de la información proporcionada, reduciendo además el riesgo de respuestas erróneas o “alucinaciones” del modelo.

Por su parte, el aprendizaje federado permite entrenar algoritmos de IA utilizando datos distribuidos en diferentes hospitales o centros sanitarios sin necesidad de transferir la información sensible a un servidor central. Los modelos se entrenan localmente y únicamente se comparten los parámetros aprendidos, favoreciendo la privacidad, la seguridad de los datos y el cumplimiento normativo en entornos clínicos.

La integración de estas tres herramientas busca desarrollar sistemas más precisos, personalizados y seguros, capaces de aprovechar información clínica actualizada manteniendo la protección de los datos de los pacientes.

Además, permiten incorporar conocimiento actualizado procedente de guías clínicas y bases de datos nutricionales, así como adaptar las recomendaciones a contextos culturales específicos, manteniendo al mismo tiempo los datos sensibles en entornos locales seguros.

No obstante, la evidencia disponible se basa fundamentalmente en estudios de simulación o entornos controlados. Aunque algunos modelos han demostrado una elevada concordancia con recomendaciones dietéticas estandarizadas en estos contextos, su rendimiento en condiciones reales, caracterizadas por información incompleta o heterogénea, es considerablemente más variable.

Desde el punto de vista cuantitativo, estudios preliminares sugieren que, cuando se dispone de información detallada sobre ingredientes y cantidades, los errores en la estimación de macronutrientes pueden situarse en rangos comparables a los métodos tradicionales. Sin embargo, en escenarios con información limitada, situación habitual en la práctica clínica, la precisión disminuye de forma significativa, lo que limita su uso autónomo en decisiones críticas como el ajuste de dosis de insulina<sup>11</sup>.

Además, se han descrito limitaciones relacionadas con la generación de información inexacta o no verificable, la falta de trazabilidad de las fuentes y la variabilidad en las respuestas generadas, lo que plantea retos adicionales para su uso en entornos clínicos.

En este contexto, los LLM deben considerarse herramientas de apoyo para la educación nutricional y la generación de recomendaciones orientativas, más que sistemas autónomos de toma de decisiones clínicas.

### Asistentes conversacionales

Más allá de la automatización del registro dietético, la IA conversacional ha emergido como una herramienta relevante para la educación terapéutica en DM. Los asistentes conversacionales basados en procesamiento del lenguaje natural permiten responder dudas nutricionales, interpretar datos de MCG y reforzar mensajes educativos de forma continua, superando las limitaciones temporales de la consulta presencial. Diversos estudios han demostrado que los agentes conversacionales pueden mejorar el conocimiento del paciente y facilitar la adquisición de habilidades de autocuidado en enfermedades crónicas<sup>12</sup>.

Algunas plataformas utilizan estos sistemas como entornos de entrenamiento clínico, simu-

lando entrevistas nutricionales y escenarios de toma de decisiones, mientras que otras los orientan directamente al paciente como soporte educativo diario. Un ejemplo es el *chatbot* de dieta baja en carbohidratos desarrollado por el Michigan Collaborative for Type 2 Diabetes, inicialmente diseñado con fines formativos y posteriormente adaptado para su uso como herramienta de apoyo educativo<sup>13</sup>. Los sistemas más avanzados integran datos reales del paciente (glucosa, actividad, registros dietéticos) para contextualizar las respuestas.

En estudios de intervención, este enfoque se ha asociado a incrementos significativos en el compromiso del paciente y mejoras modestas, pero sostenidas, en la adherencia al tratamiento nutricional<sup>14</sup>. Sin embargo, persisten riesgos relacionados con la simplificación excesiva de mensajes complejos y con la generación de recomendaciones no contextualizadas si no existe supervisión profesional.

### Predicción individualizada de la respuesta glucémica posprandial

Uno de los avances más relevantes de la IA aplicada a la nutrición es la capacidad de predecir la respuesta glucémica posprandial de forma individualizada. Modelos de aprendizaje automático que incorporan múltiples variables, como glucosa preprandial, tendencia glucémica previa, composición nutricional, actividad física y cronobiología, han demostrado una capacidad predictiva claramente superior a los modelos basados exclusivamente en el contenido de carbohidratos.

Xiong *et al.*<sup>5</sup> mostraron que un modelo basado en LightGBM alcanzaba una correlación significativa ( $r = 0,63$ ) entre valores predichos y observados, frente a una correlación mínima ( $r = 0,14$ ) cuando solo se consideraban los hidratos de carbono. Estos resultados tienen implicaciones clínicas relevantes, especialmente para la dosificación de insulina prandial y la prevención de hipoglucemias tardías.

Algunos proyectos de gran escala, incluyendo estudios longitudinales con monitorización continua y cohortes amplias, han generado evidencia sólida sobre la variabilidad interindividual en la respuesta glucémica y han permitido refinar

modelos predictivos que integran factores como el microbioma, el sueño o el estilo de vida<sup>15,16</sup>.

Desde una perspectiva clínica, estas aplicaciones comparten tres mecanismos fundamentales: la automatización de tareas complejas, la adaptación individualizada de las recomendaciones y el refuerzo sostenido del autocuidado. La combinación de estos elementos permite explicar gran parte de los beneficios observados en términos de control glucémico y adherencia terapéutica. Sin embargo, la implementación clínica de estos modelos se ve limitada por su complejidad, la necesidad de grandes volúmenes de datos y la dificultad para su integración en sistemas asistenciales rutinarios.

En conjunto, estas aplicaciones reflejan el potencial de la IA para transformar el manejo nutricional de la DM desde un enfoque reactivo a uno predictivo y personalizado. No obstante, su implementación efectiva requiere una evaluación crítica de su precisión, utilidad clínica y aplicabilidad en contextos reales, aspectos que se abordan en los siguientes epígrafes.

>>PRECISIÓN, VALIDACIÓN Y LÍMITES DE LAS HERRAMIENTAS ACTUALES

A pesar del rápido desarrollo de las aplicaciones basadas en IA en nutrición, su precisión y fiabilidad dependen de forma crítica del contexto de uso y de la calidad, completitud y representatividad de los datos de entrada. Diversos estudios han

demostrado que el rendimiento de estos sistemas es aceptable en condiciones controladas, cuando se dispone de información detallada sobre la ingesta, pero disminuye de forma significativa en entornos reales caracterizados por datos incompletos, heterogéneos o imprecisos, como ocurre frecuentemente en comidas fuera del domicilio o en preparaciones culinarias complejas.

Esta variabilidad en el rendimiento tiene implicaciones clínicas relevantes. El uso no supervisado de herramientas de IA para la estimación de carbohidratos o la generación de recomendaciones nutricionales puede conllevar errores con impacto directo en la dosificación de insulina, aumentando el riesgo tanto de hipoglucemias como de hiperglucemias, especialmente en pacientes con elevada variabilidad glucémica.

Desde el punto de vista metodológico, uno de los principales retos es la validación externa de los modelos. Muchos algoritmos han sido entrenados y evaluados en poblaciones específicas o en entornos controlados, lo que limita su generalización a contextos clínicos diversos. Además, la falta de estandarización en los conjuntos de datos y en los métodos de evaluación dificulta la comparación entre estudios y la interpretación de los resultados.

Otro aspecto crítico es la interpretabilidad de los modelos. La naturaleza opaca de algunos algoritmos, particularmente aquellos basados en aprendizaje profundo, puede dificultar la comprensión de los factores que determinan una

| TABLA II. APLICACIONES DE LA INTELIGENCIA ARTIFICIAL EN EL MANEJO NUTRICIONAL DE LA DIABETES |                                   |                                             |                                                                 |                                     |
|----------------------------------------------------------------------------------------------|-----------------------------------|---------------------------------------------|-----------------------------------------------------------------|-------------------------------------|
| Aplicación                                                                                   | Tecnología principal              | Función clínica                             | Evidencia disponible                                            | Limitaciones principales            |
| Reconocimiento de alimentos                                                                  | Visión computacional              | Estimación de ingesta y carbohidratos       | Estudios de validación, un estudio intervención <sup>7-10</sup> | Baja precisión en platos complejos  |
| Modelos de lenguaje (LLM)                                                                    | NLP, RAG                          | Generación de recomendaciones nutricionales | Estudios preliminares / simulación <sup>11</sup>                | Alucinaciones, baja trazabilidad    |
| Asistentes conversacionales                                                                  | NLP conversacional                | Educación terapéutica y soporte             | Revisiones sistemáticas <sup>12-14</sup>                        | Riesgo de simplificación            |
| Predicción glucémica                                                                         | Machine learning (LightGBM, etc.) | Predicción posprandial y ajuste terapéutico | Estudios observacionales <sup>5,15,16</sup>                     | Complejidad, difícil implementación |

LLM (Large Language Model): modelos de lenguaje de gran escala; NLP (Natural Language Processing): Procesamiento del Lenguaje Natural; RAG (Retrieval-Augmented Generation): Generación Aumentada por Recuperación

recomendación concreta, lo que limita su aceptación por parte de los profesionales sanitarios y plantea desafíos en términos de responsabilidad clínica y toma de decisiones compartida<sup>17</sup>.

A estas limitaciones se suman consideraciones relacionadas con la equidad y la representatividad de los datos. Los modelos entrenados en poblaciones específicas pueden no capturar adecuadamente la diversidad cultural, dietética y metabólica de otros grupos, lo que puede introducir sesgos y reducir la precisión en determinados contextos.

En este contexto, la IA debe entenderse como un sistema de soporte a la decisión clínica, cuya utilidad depende de su integración crítica en el proceso asistencial, y no como un sustituto del juicio clínico ni del conocimiento experiencial del paciente.

## >>EVIDENCIA CLÍNICA DE EFECTIVIDAD

### Ensayos clínicos y estudios de intervención

La evidencia clínica disponible muestra una heterogeneidad considerable en función del tipo de intervención, la duración del seguimiento y el grado de integración con el equipo sanitario. En general, las intervenciones digitales basadas en IA parecen ser más eficaces cuando se combinan con MCG y retroalimentación clínica personalizada.

Uno de los estudios más relevantes es el ensayo aleatorizado de Lee *et al.*<sup>7</sup>, que evaluó la plataforma FoodLens en 224 adultos con diabetes tipo 2 y sobrepeso u obesidad durante 48 semanas. Los participantes fueron asignados a tres grupos: (A) cuidado rutinario, (B) plataforma digital y (C) plataforma digital combinada con MCG y retroalimentación clínica. Los resultados mostraron mejoras significativas en el control glucémico, con reducciones de la HbA1c más pronunciadas en el grupo que recibió intervención combinada. Además, la automatización del registro dietético se asoció a una reducción de la carga cognitiva, facilitando la adherencia al autocuidado.

Un metaanálisis de ensayos controlados aleatorizados ha mostrado que las intervenciones basadas en aplicaciones móviles se asocian a una reducción media de la HbA1c de aproximadamente 0,4-0,5 % en comparación con el cuidado habitual.

En particular, las intervenciones que incorporan elementos interactivos, personalización y retroalimentación continua parecen obtener mejores resultados que aquellas basadas en recordatorios simples o estrategias unidireccionales<sup>18</sup>.

No obstante, estos resultados deben interpretarse con cautela. Existe una notable heterogeneidad entre estudios en términos de diseño, población, duración del seguimiento y componentes de la intervención. Además, muchas intervenciones combinan múltiples elementos, como educación, monitorización y *feedback* clínico, lo que dificulta aislar el efecto específico de la IA como componente independiente.

Diversos análisis sugieren que el grado de compromiso del paciente con la herramienta digital constituye un determinante clave de su eficacia clínica, superando en algunos casos el impacto de la tecnología en sí misma. La evidencia sugiere que las intervenciones que incorporan comunicación bidireccional con el equipo sanitario muestran mejores resultados que aquellas basadas exclusivamente en automatización, lo que refuerza el papel central del profesional en el ecosistema digital.

En conjunto, estos datos sugieren que el beneficio clínico de estas intervenciones depende en gran medida de su grado de integración en el proceso asistencial y de su capacidad de personalización.

### Limitaciones metodológicas

No obstante, la mayoría de los estudios presentan limitaciones metodológicas relevantes que deben considerarse al interpretar sus resultados. Entre ellas destacan la corta duración del seguimiento, frecuentemente limitada a 3-6 meses, el reducido tamaño muestral en algunos ensayos y la inclusión de poblaciones seleccionadas, lo que limita la extrapolación de los hallazgos a la práctica clínica habitual.

Además, existe una notable heterogeneidad en el diseño de las intervenciones, que a menudo combinan múltiples componentes, educación, monitorización, retroalimentación clínica y herramientas digitales, lo que dificulta identificar el efecto específico atribuible a la IA como elemento independiente.

Otro aspecto relevante es la falta de evaluación de la sostenibilidad de los beneficios a largo plazo. Aunque muchas intervenciones muestran mejoras iniciales en el control glucémico o la adherencia, son escasos los estudios que analizan la persistencia de estos efectos más allá del primer año de seguimiento.

Por otra parte, persisten brechas relevantes en la representatividad de los datos utilizados para el desarrollo de estos modelos. La mayoría de los algoritmos se han entrenado en poblaciones de países de ingresos medios y altos, lo que limita su generalización a otros contextos. Estudios de validación externa han mostrado que el rendimiento de estos sistemas puede disminuir cuando se aplican en poblaciones con diferentes características sociodemográficas o patrones dietéticos, lo que sugiere la presencia de sesgos algorítmicos con potencial impacto clínico<sup>19</sup>.

A ello se suma una limitada cobertura lingüística y cultural. Muchos sistemas han sido desarrollados a partir de bases de datos predominantemente occidentales, lo que dificulta su aplicación en contextos con alta diversidad culinaria. Esta limitación resulta especialmente relevante en regiones como Latinoamérica, África o Asia, donde la variabilidad en ingredientes, preparaciones y hábitos alimentarios puede comprometer la precisión de las recomendaciones generadas.

Finalmente, la variabilidad en los desenlaces evaluados y la falta de estandarización en los métodos de medición dificultan la comparación entre estudios y la realización de síntesis cuantitativas robustas.

## >>NUTRICIÓN DE PRECISIÓN AVANZADA Y MICROBIOMA

La integración del microbioma intestinal en modelos predictivos de respuesta glucémica representa uno de los desarrollos más avanzados dentro del campo de la nutrición de precisión. Estudios pioneros han demostrado que la respuesta glucémica a alimentos específicos está significativamente modulada por la composición microbiana individual, superando la capacidad predictiva de enfoques tradicionales basados únicamente en el índice glucémico<sup>20</sup>.

Sobre esta base, plataformas comerciales como ZOE o DayTwo han trasladado estos hallazgos a aplicaciones clínicas, aunque con distintos niveles de validación independiente.

## >>GEMELOS DIGITALES

Un desarrollo emergente es el concepto de gemelo digital metabólico, que consiste en la creación de modelos computacionales personalizados capaces de simular la respuesta del organismo a diferentes intervenciones nutricionales y terapéuticas. Este enfoque permite, al menos teóricamente, anticipar el efecto de cambios dietéticos antes de su implementación en la vida real. En este contexto, intervenciones intensivas basadas en plataformas digitales integradas, como el programa Twin Health, han mostrado resultados prometedores, incluyendo tasas elevadas de remisión de diabetes tipo 2 y mejoras significativas en peso y control metabólico<sup>21</sup>. Sin embargo, estos resultados deben interpretarse con cautela, ya que estas intervenciones combinan múltiples componentes, monitorización continua, soporte intensivo, cambios conductuales y ajuste terapéutico, lo que dificulta atribuir los efectos observados exclusivamente al uso de modelos de gemelo digital.

Además, la aplicabilidad de estos enfoques en la práctica clínica habitual es actualmente limitada, debido a su elevada complejidad, coste y requerimientos tecnológicos. Asimismo, persisten interrogantes sobre su reproducibilidad, validación en poblaciones diversas y sostenibilidad a largo plazo.

Estos avances ilustran el potencial futuro de la IA en nutrición, pero también ponen de manifiesto la necesidad de abordar las barreras de implementación y las consideraciones éticas asociadas a su uso.

## >>HERRAMIENTAS DISPONIBLES EN ESPAÑOL Y CONTEXTO IBEROAMERICANO

En el ámbito hispanohablante existen diversas aplicaciones orientadas al manejo de la DM que incorporan funcionalidades relacionadas con el control nutricional y el apoyo al autocuidado.

Algunas de ellas, como mySugr PRO o SocialDiabetes, cuentan con certificación como producto sanitario (CE) y permiten integrar registros dietéticos, el cálculo de bolos y compartir datos con el equipo sanitario, facilitando su uso en la práctica clínica.

Otras herramientas emergentes, como DiabTrend o Foodvisor, han comenzado a incorporar funcionalidades basadas en IA, incluyendo reconocimiento automático de alimentos y estimación nutricional, aunque con distintos niveles de validación clínica y menor integración en sistemas asistenciales.

En el ámbito del reconocimiento automático de alimentos, destacan soluciones como LogMeal, desarrollada en España, así como otras plataformas como goFOOD, GoCARB o Snap-n-Eat, que han sido evaluadas en contextos de investigación, incluyendo población con DM. No obstante, su implementación en la práctica clínica sigue siendo limitada.

Más allá de la disponibilidad tecnológica, la implementación de estas herramientas en España y Latinoamérica se enfrenta a barreras estructurales relevantes. Entre ellas destaca la brecha digital, con desigualdades en el acceso a tecnologías de la información que pueden condicionar la adopción de estas soluciones, especialmente en poblaciones vulnerables.

Asimismo, la limitada interoperabilidad con los sistemas de historia clínica electrónica de los

sistemas públicos de salud dificulta la integración de estas herramientas en el flujo asistencial habitual, reduciendo su utilidad para los profesionales sanitarios.

Desde el punto de vista regulatorio, la complejidad del Reglamento (UE) 2017/745 sobre Productos Sanitarios ha supuesto un desafío adicional para el desarrollo y la comercialización de nuevas soluciones digitales, especialmente para pequeñas empresas y entornos de innovación. A ello se suma la ausencia de mecanismos de financiación o reembolso público para la mayoría de estas herramientas, lo que limita su acceso equitativo y su adopción a gran escala<sup>22</sup>.

En conjunto, estos factores ponen de manifiesto que, más allá del desarrollo tecnológico, la implementación efectiva de la IA en el manejo nutricional de la DM en el contexto iberoamericano requiere abordar barreras estructurales, regulatorias y organizativas.

En la [tabla III](#) se resumen algunas de las principales herramientas disponibles en el ámbito hispanohablante y sus características más relevantes.

## >> PERSPECTIVA DE GÉNERO Y POBLACIONES ESPECÍFICAS

Las diferencias de género en el autocuidado de la DM han sido históricamente infrarrepresentadas tanto en la investigación clínica como en el diseño de herramientas digitales. La evidencia

**TABLA III. HERRAMIENTAS DIGITALES DISPONIBLES EN ESPAÑOL PARA EL MANEJO DE LA DIABETES**

| Herramienta    | Función principal                      | Características clave                                               | Estado regulatorio/evidencia             |
|----------------|----------------------------------------|---------------------------------------------------------------------|------------------------------------------|
| mySugr PRO     | Diario de diabetes multifunción        | Cálculo de bolos, registro glucémico, generación de informes        | Dispositivo médico (UE)                  |
| SocialDiabetes | Gestión integral de diabetes           | Compartición de datos con profesionales, sincronización en la nube  | Dispositivo médico (UE)                  |
| LogMeal        | Reconocimiento automático de alimentos | Análisis automatizado de platos mediante IA                         | Validación preliminar                    |
| DiabTrend      | Reconocimiento automático de alimentos | Identificación de comidas y estimación de carbohidratos mediante IA | Validación preliminar                    |
| FoodLens       | IA nutricional integrada               | Integración con MCG y evidencia clínica                             | Ensayo clínico aleatorizado <sup>7</sup> |

IA: inteligencia artificial; MCG: monitorización continua de glucosa; UE: Unión Europea.

disponible sugiere que hombres y mujeres presentan patrones diferenciados en el manejo de la enfermedad, influenciados por factores biológicos, conductuales y psicosociales<sup>4,23</sup>.

En términos generales, las mujeres tienden a experimentar una mayor carga emocional y de cuidado asociada al manejo de la DM, mientras que en los hombres la autoeficacia, entendida como la percepción de capacidad para llevar a cabo conductas de autocuidado, emerge como un predictor más relevante de resultados clínicos. Estas diferencias tienen implicaciones directas en el diseño y la implementación de intervenciones digitales, incluyendo aquellas basadas en IA.

### Diferencias en conocimiento y autoeficacia

Estudios de intervención en poblaciones vulnerables, como el programa TEXT-MED (*Telemonitoring and Text Messaging for Mobile Diabetes Management*) en pacientes con diabetes tipo 2 de bajo nivel socioeconómico, han mostrado respuestas diferenciadas según el género<sup>24</sup>. En este contexto, las mujeres experimentaron mejoras significativas en el conocimiento sobre la enfermedad, mientras que los hombres mostraron un mayor incremento en la autoeficacia tras la intervención.

Estos hallazgos sugieren que las estrategias digitales podrían requerir enfoques diferenciados: intervenciones centradas en educación estructurada y validación de información en mujeres, frente a estrategias orientadas a reforzar la confianza y la toma de decisiones en hombres. No obstante, estas tendencias deben interpretarse con cautela, dada la variabilidad individual y el papel de factores socioculturales.

### Diferencias en la carga de autocuidado

Desde una perspectiva cualitativa, diversos estudios han evidenciado que las mujeres con DM, especialmente en el contexto de diabetes tipo 2, asumen una mayor carga de autocuidado. Esta carga no se limita al manejo individual de la enfermedad, sino que frecuentemente se extiende al cuidado de otros miembros de la familia.

A ello se añaden factores específicos, como las fluctuaciones hormonales a lo largo del ciclo vital (menstruación, embarazo, menopausia) y

una mayor exposición a estresores psicosociales, que pueden influir tanto en el control glucémico como en la adherencia terapéutica. Estas dimensiones son escasamente consideradas en el diseño actual de herramientas digitales.

### Brechas en herramientas específicas y diabetes gestacional

A pesar de estas diferencias, la mayoría de las herramientas de IA aplicadas al manejo nutricional de la DM no incorporan una perspectiva de género explícita. Esto se traduce en limitaciones en aspectos como la personalización del contenido educativo, la adaptación a necesidades específicas relacionadas con la salud reproductiva o la consideración de dinámicas familiares en el autocuidado.

Un vacío especialmente relevante es el de la diabetes gestacional. A pesar de su elevada prevalencia y de su impacto en el riesgo futuro de diabetes tipo 2, existen pocas herramientas digitales, y aún menos basadas en IA, diseñadas específicamente para este contexto<sup>25</sup>. Las mujeres con diabetes gestacional pueden enfrentar, además, barreras adicionales relacionadas con la accesibilidad tecnológica y la adecuación de las herramientas disponibles, que a menudo han sido diseñadas para otros perfiles de pacientes.

En conjunto, la incorporación de una perspectiva de género en el desarrollo de herramientas de IA representa una oportunidad clave para mejorar su relevancia clínica, su aceptación por parte de los pacientes y su impacto en resultados en salud.

## >> BARRERAS DE IMPLEMENTACIÓN Y CONSIDERACIONES ÉTICAS

Las barreras a la adopción de herramientas basadas en IA en el manejo nutricional de la DM operan a múltiples niveles, incluyendo el profesional sanitario, el paciente y el sistema de salud. Estas limitaciones no solo condicionan la implementación de estas tecnologías, sino que también plantean desafíos éticos relevantes (tabla IV).

Desde la perspectiva de los profesionales sanitarios, las principales barreras incluyen la incertidumbre sobre el rendimiento clínico de estas

**TABLA IV. BARRERAS Y OPORTUNIDADES EN LA IMPLEMENTACIÓN DE LA INTELIGENCIA ARTIFICIAL EN EL MANEJO NUTRICIONAL DE PERSONAS CON DIABETES MELLITUS**

| Nivel                        | Barreras principales                                                                                                                                     | Oportunidades                                                                                                                                                     |
|------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <b>Profesional sanitario</b> | Falta de formación específica en IA; incertidumbre sobre el rendimiento clínico; opacidad de los algoritmos; escasa integración en el flujo asistencial. | Desarrollo de programas de formación; implementación de IA explicable; herramientas integradas en historia clínica electrónica.                                   |
| <b>Paciente</b>              | Baja alfabetización digital; desconfianza en recomendaciones automatizadas; costes asociados; falta de adaptación cultural.                              | Interfaces más accesibles; personalización de recomendaciones; herramientas culturalmente adaptadas; mayor participación del paciente.                            |
| <b>Sistema sanitario</b>     | Complejidad regulatoria (MDR); ausencia de modelos de reembolso; falta de interoperabilidad; fragmentación de sistemas de información.                   | Desarrollo de marcos regulatorios adaptados; inclusión en sistemas de financiación; estándares de interoperabilidad (FHIR/HL7); integración en sistemas de salud. |

FHIR (Fast Healthcare Interoperability Resources)/HL7 (Health Level Seven); IA: inteligencia artificial; MDR: Reglamento (UE) 2017/745 sobre Productos Sanitarios.

herramientas, la falta de formación específica y la limitada transparencia de los algoritmos. Muchos clínicos expresan dudas sobre si las recomendaciones generadas por sistemas de IA aportan un valor añadido respecto al juicio clínico basado en la experiencia. Además, la escasa inclusión de contenidos relacionados con IA en los programas de formación en DM dificulta su adopción crítica y segura. A ello se suma la naturaleza opaca de algunos modelos, que dificulta la interpretación de sus recomendaciones y genera desconfianza<sup>17</sup>.

En el ámbito del paciente, las barreras más relevantes incluyen la alfabetización digital, la confianza en las recomendaciones generadas por IA, los costes asociados y la adecuación cultural de las herramientas. Factores como la edad, el nivel educativo y el acceso a tecnologías digitales condicionan significativamente el uso de estas aplicaciones. Asimismo, la percepción de falta de transparencia o de sesgo en los algoritmos puede reducir la confianza del usuario. Por otro lado, aunque muchas aplicaciones ofrecen versiones gratuitas, las funcionalidades avanzadas suelen requerir suscripciones, lo que puede limitar el acceso en poblaciones vulnerables. La falta de adaptación a preferencias culturales y patrones dietéticos locales constituye otra barrera adicional para su adopción.

A nivel del sistema sanitario, las barreras estructurales incluyen la complejidad regulatoria, la falta de modelos de financiación y las limitaciones en la interoperabilidad de los sistemas de información. El Reglamento (UE) 2017/745

sobre Productos Sanitarios establece requisitos estrictos para la validación clínica y la comercialización de herramientas digitales, lo que puede ralentizar la innovación, especialmente en entornos con recursos limitados. Asimismo, la ausencia de mecanismos de reembolso en muchos sistemas de salud públicos limita la adopción a gran escala de estas soluciones. La fragmentación de los sistemas de información y la escasa integración con las historias clínicas electrónicas dificultan además su incorporación en la práctica asistencial rutinaria.

Desde una perspectiva ética, la protección de datos personales y la equidad en el acceso constituyen aspectos clave. Normativas como el Reglamento General de Protección de Datos imponen restricciones necesarias para garantizar la privacidad, pero pueden limitar el uso de datos para el entrenamiento y mejora de algoritmos. En este contexto, enfoques como el aprendizaje federado y el desarrollo de modelos explicables han sido propuestos como estrategias para equilibrar la utilidad clínica con la protección de los datos y la transparencia algorítmica.

En conjunto, la implementación efectiva de la IA en el manejo nutricional de la DM requiere no solo avances tecnológicos, sino también el desarrollo de marcos regulatorios, formativos y organizativos que permitan su integración segura, equitativa y clínicamente relevante.

Estas barreras subrayan la necesidad de traducir el potencial tecnológico en recomendaciones

prácticas para su integración en la práctica clínica, aspecto que se aborda en el siguiente epígrafe.

La ausencia de estándares de interoperabilidad ampliamente adoptados, como FHIR o HL7, limita la integración efectiva de estas herramientas en los sistemas clínicos, reduciendo su aplicabilidad en la práctica asistencial.

## >>IMPlicACIONES CLíNICAS Y RECOMENDACIONES PARA PROFESIONALES SANITARIOS

La integración de la IA en el manejo nutricional de la DM requiere un enfoque selectivo, crítico y centrado en el paciente. Aunque estas herramientas ofrecen oportunidades para mejorar la personalización del tratamiento y optimizar el tiempo clínico, su implementación debe realizarse de forma progresiva y bajo supervisión profesional. En este contexto, la IA debe entenderse como un sistema de apoyo a la toma de decisiones, que complementa, pero no sustituye, el juicio clínico ni la relación terapéutica.

Desde la perspectiva del profesional sanitario, es fundamental priorizar el uso de herramientas que cuenten con validación clínica adecuada y que puedan integrarse en el flujo asistencial habitual. Asimismo, resulta necesario desarrollar competencias específicas en la interpretación crítica de las recomendaciones generadas por IA, evitando su uso acrítico. La comunicación con el paciente debe ser transparente, explicando tanto el potencial como las limitaciones de estas herramientas. Además, la selección de soluciones digitales debería tener en cuenta factores como el contexto sociocultural y las diferencias de género, incluyendo necesidades específicas relacionadas con la salud reproductiva o las dinámicas familiares.

En relación con los pacientes, el uso de herramientas basadas en IA debe plantearse de forma progresiva, comenzando por aplicaciones con funciones concretas y bien validadas, como el registro dietético o el reconocimiento de alimentos. Es recomendable fomentar una actitud activa y crítica, en la que el paciente contraste las recomendaciones con su experiencia previa y comunique al equipo sanitario cualquier discrepancia relevante. Este enfoque favorece un

uso más seguro y contribuye a mejorar la calidad de las herramientas mediante retroalimentación continua.

Desde el punto de vista del sistema sanitario y las políticas de salud, la adopción efectiva de estas tecnologías requiere el desarrollo de marcos regulatorios y de financiación adecuados. La simplificación de los procesos de evaluación para herramientas de bajo riesgo, junto con la inclusión de aplicaciones validadas en los sistemas de reembolso, puede facilitar su acceso equitativo. Asimismo, resulta esencial invertir en infraestructuras interoperables que permitan la integración de datos procedentes de aplicaciones en las historias clínicas electrónicas. Por último, es necesario promover el desarrollo y la validación de algoritmos en poblaciones diversas, así como implementar estrategias de equidad digital que garanticen el acceso a estas tecnologías en grupos vulnerables.

Entre las principales oportunidades de desarrollo destacan la mejora del reconocimiento de alimentos en contextos de alta diversidad culinaria, el desarrollo de herramientas específicas para diabetes gestacional, la integración accesible de datos de microbioma en la práctica clínica y la creación de sistemas interoperables que permitan una comunicación bidireccional efectiva entre pacientes y profesionales sanitarios.

## >>CONCLUSIONES

Las herramientas de IA han transformado de forma sustancial el manejo nutricional de la DM desde 2020, pasando de desarrollos experimentales a aplicaciones clínicas con evidencia de eficacia en ensayos controlados. Estas tecnologías han demostrado su capacidad para optimizar el manejo nutricional mediante la automatización de tareas complejas, la adaptación individualizada de las recomendaciones y el refuerzo sostenido del autocuidado.

Entre los avances más destacados se encuentran el reconocimiento automatizado de alimentos, los modelos predictivos de respuesta glucémica individualizada y la integración de datos multimodales, incluyendo variables conductuales y biológicas. Asimismo, el desarrollo de enfoques de nutrición de precisión, apoyados en el análisis del microbioma y otras fuentes de datos

complejos, abre nuevas perspectivas para una personalización más avanzada del tratamiento.

No obstante, el panorama actual sigue siendo heterogéneo y fragmentado. Persisten limitaciones relevantes en términos de validación clínica, sostenibilidad a largo plazo y generalización a contextos culturales diversos. La mayoría de las herramientas han sido desarrolladas en poblaciones de países de ingresos medios y altos, lo que plantea desafíos en términos de equidad y riesgo de sesgos algorítmicos. Además, existen lagunas importantes en áreas específicas, como la diabetes gestacional o la adaptación de las intervenciones a diferencias de género y dinámicas familiares.

Desde el punto de vista de la implementación, las barreras estructurales, la interoperabilidad limitada, la falta de modelos de financiación y la complejidad regulatoria, continúan dificultando la integración efectiva de estas herramientas en la práctica clínica. Asimismo, la limitada incorporación de estas soluciones en los flujos asistenciales habituales reduce su impacto potencial en resultados en salud.

El desarrollo futuro de la IA en nutrición aplicada a la DM deberá orientarse hacia modelos más robustos, explicables y validados en poblaciones diversas, incorporando de forma explícita principios de equidad, diseño centrado en el usuario y adaptación cultural. La implicación activa de pacientes y profesionales en el desarrollo de estas herramientas será clave para mejorar su aceptabilidad y utilidad clínica.

En este contexto, la IA no debe entenderse como un sustituto del profesional sanitario, sino como una herramienta de apoyo que amplía su capacidad de análisis y personalización. Su valor real residirá en su integración crítica en el proceso asistencial, contribuyendo a una medicina más precisa, pero también más humana, contextualizada y equitativa.

### Conflictos de intereses

Los autores declaran no tener ningún conflicto de intereses con respecto al contenido de esta revisión.

## >> BIBLIOGRAFÍA

1. Deng M, Yang R, Zheng X, Deng Y, Jiang J. Artificial intelligence in diabetes care: from predictive analytics to generative AI and implementation challenges. *Front Endocrinol (Lausanne)*. 2025;16:1620132. DOI: 10.3389/fendo.2025.1620132.
2. Mackenzie SC, Sainsbury CAR, Wake DJ. Diabetes and artificial intelligence beyond the closed loop: a review of the landscape, promise and challenges. *Diabetologia*. 2024;67(2):223-35. DOI: 10.1007/s00125-023-06038-8.
3. Housni A, Katz A, Bergeron LJ, Simard A, Finkel A, Roy-Fleming A, *et al*. Bridging the gap in carbohydrate counting with a mobile app: needs assessment survey. *J Med Internet Res*. 2025;27:e63278. DOI: 10.2196/63278.
4. Ramírez-Morros A, Berenguera A, Millaruelo L, Buil-Cosiales P, Gómez-García C, Cos X, *et al*. Impact of gender on patient experiences of self-management in type 2 diabetes: a qualitative study. *Patient Prefer Adherence*. 2024;18:1885-96. DOI: 10.2147/PPA.S466931.
5. Xiong X, Xue Y, Cai Y, He J, Su H. Prediction of personalised postprandial glycaemic response in type 1 diabetes mellitus. *Front Endocrinol (Lausanne)*. 2024;15:1423303. DOI: 10.3389/fendo.2024.1423303.
6. Fraser RA, Walker RJ, Campbell JA, Ekwunife O, Egede LE. Integration of artificial intelligence and wearable technology in the management of diabetes and prediabetes. *NPJ Digit Med*. 2025;8:687. DOI: 10.1038/s41746-025-02036-9.
7. Lee YB, Kim G, Jun JE, Park H, Lee WJ, Hwang YC, *et al*. An integrated digital health care platform for diabetes management with AI-based dietary management: 48-week results from a randomized controlled trial. *Diabetes Care*. 2023;46(5):959-66. DOI: 10.2337/dc22-1929.
8. Liu D, Zuo E, Wang D, He L, Dong L, Lu X. Deep learning in food image recognition: a comprehensive review. *Appl Sci*. 2025;15(14):7626. DOI: 10.3390/app15147626.
9. Dalakleidi KV, Papadelli M, Kapolos I, Papadimitriou K. Applying image-based food-recognition systems on dietary assessment: a systematic review. *Adv Nutr*. 2022;13:2590-2619. DOI: 10.1093/advances/nmac078.
10. Boushey CJ, Spoden M, Zhu FM, Delp EJ, Kerr DA. New mobile methods for dietary assessment: review of image-assisted and image-based methods. *Proc Nutr Soc*. 2017;76(3):283-94. DOI: 10.1017/S0029665116002913.
11. Tecce N, Vetrani C, Pelosi AL, Alfio M, Mayol D, Maddaloni MG, *et al*. AI-powered carbohydrate counting for type 1 diabetes: accuracy and real-world performance. *Diabetes Care*. 2025;48(8):e97-8. DOI: 10.2337/dc25-0303.
12. Schachner T, Keller R, Wangenheim FV. Artificial intelligence-based conversational agents for chronic conditions: systematic review. *J Med Internet Res*. 2020;22(9):e20701. DOI: 10.2196/20701.

13. Michigan Collaborative for Type 2 Diabetes. Low-carb chatbot [Internet]. Ann Arbor (MI): MCT2D [consultado 13/04/2026]. Disponible en: <https://www.mct2d.org/low-carb-chatbot>.
14. Laranjo L, Dunn AG, Tong HL, Kocaballi AB, Chen J, Bashir R, *et al*. Conversational agents in healthcare: a systematic review. *J Am Med Inform Assoc*. 2018;25(9):1248-58. DOI: 10.1093/jamia/ocy072.
15. Zeevi D, Korem T, Zmora N, Israeli D, Rothschild D, Weinberger A, *et al*. Personalized nutrition by prediction of glycemic responses. *Cell*. 2015;163(5):1079-94. DOI: 10.1016/j.cell.2015.11.001.
16. Berry SE, Valdes AM, Drew DA, Asnicar F, Mazidi M, Wolf J, *et al*. Human postprandial responses to food and potential for precision nutrition. *Nat Med*. 2020;26:964-73. DOI: 10.1038/s41591-020-0934-0.
17. Cangelosi G, Conti A, Caggianelli G, Panella M, Petrelli F, Mancin S, *et al*. Barriers and facilitators to artificial intelligence implementation in diabetes management: a scoping review. *Medicina (Kaunas)*. 2025;61(8):1403. DOI: 10.3390/medicina61081403.
18. Hou C, Xu Q, Diao S, Hewitt J, Li J, Carter B. Mobile phone applications and self-management of diabetes: a systematic review with meta-analysis. *Diabetes Obes Metab*. 2018;20(8):2009-13. DOI: 10.1111/dom.13307.
19. Osonuga A, Osonuga AA, Fidelis SC, Osonuga GC, Juckes J, Olawade DB. Bridging the digital divide: artificial intelligence as a catalyst for health equity in primary care settings. *Int J Med Inform*. 2025;204:106051. DOI: 10.1016/j.ijmedinf.2025.106051.
20. Guizar-Heredia R, Noriega LG, Rivera AL, Resendis-Antonio O, Guevara-Cruz M, Torres N, *et al*. A new approach to personalized nutrition: postprandial glycemic response and its relationship to gut microbiota. *Arch Med Res*. 2023;54(3):176-88. DOI: 10.1016/j.arcmed.2023.02.007.
21. Joshi S, Shamanna P, Dharmalingam M, Vadavi A, Keshavamurthy A, Shah L, *et al*. Digital twin-enabled personalized nutrition improves metabolic dysfunction-associated fatty liver disease in type 2 diabetes: results of a 1-year randomized controlled study. *Endocr Pract*. 2023;29(12):960-70. DOI: 10.1016/j.eprac.2023.08.016.
22. Bosch-Frigola I, Coca-Villalba F, Pérez-Lacasta MJ, Carles-Lavila M. Diabetes mellitus and inequalities in the use of information technologies as a socioeconomic determinant of health in Spain. *Front Public Health*. 2023;10:1033461. DOI: 10.3389/fpubh.2022.1033461.
23. Burner E, Menchine M, Taylor E, Arora S. Gender differences in diabetes self-management: a mixed-methods analysis of a mobile health intervention. *J Diabetes Sci Technol*. 2013;7(1):111-8. DOI: 10.1177/193229681300700113.
24. Arora S, Peters AL, Agy C, Menchine M. A mobile health intervention for inner-city patients with poorly controlled diabetes: proof-of-concept of the TExT-MED program. *Diabetes Technol Ther*. 2012;14(6):492-6. DOI: 10.1089/dia.2011.0252.
25. Safiee L, Rough DJ, Whitford H. Barriers to and facilitators of using eHealth to support gestational diabetes self-management: a systematic review. *J Med Internet Res*. 2022;24(10):e39689. DOI: 10.2196/39689.