

JORNADAS

XXI Jornadas del Comité de Graduados de la Sociedad Argentina de Diabetes

Inteligencia artificial y nuevas tecnologías: transformación del ecosistema digital en la atención del paciente con diabetes

XXI Conference of the Graduate Committee of the Argentine Diabetes Society

Artificial intelligence and new technologies: transformation of the digital ecosystem in the care of patients with diabetes

Coordinadora: Carolina Figueredo¹

Secretario: Luis Biliato²

Integrantes: Laura Dimov³, Susana Beatriz Apoloni⁴, Bárbara Arinovich⁵, Roberto Aiziczon⁶, Viviana Sosa⁷

Experto invitado: Enrique Majul⁸

Compiladora: Carolina Figueredo¹

RESUMEN

Introducción: los modelos tradicionales para atender pacientes con diabetes mellitus (DM) muestran limitaciones estructurales frente al crecimiento sostenido de la demanda asistencial. La inteligencia artificial (IA) aparece aquí como una herramienta con capacidad transformadora real. Puede procesar grandes cantidades de datos clínicos, reconocer patrones que escapan del análisis convencional y sugerir recomendaciones personalizadas, abriendo posibilidades concretas para mejorar tanto los resultados en los pacientes como la eficiencia del sistema de salud.

Materiales y métodos: se realizó una búsqueda bibliográfica de tipo descriptiva, centrada en guías de práctica clínica, meta-análisis, revisiones sistemáticas y ensayos controlados. Se priorizaron las publicaciones de los últimos 5 años, y cuando fue necesario fundamentar conceptos esenciales, se recurrió a fuentes anteriores. El enfoque principal de la búsqueda fue hacia las aplicaciones de la IA y la tecnología que facilitan el trabajo del médico en el manejo diario de la DM.

Resultados: los sistemas de aprendizaje automático y profundo han mejorado el funcionamiento de las bombas de insulina automatizadas, logrando un control metabólico más preciso. La evidencia muestra que la IA contribuye al diagnóstico temprano de la DM1, la DM2 y la DM gestacional; también ayuda a predecir complicaciones crónicas y a personalizar tratamientos. Los monitores continuos de glucosa, las lapiceras inteligentes de insulina, las plataformas de descarga de datos y la telemedicina son herramientas que facilitan la integración de toda esta información para mantener el contacto efectivo con el paciente.

Conclusiones: la IA en el campo de la DM avanza rápidamente. Los profesionales que trabajan en dicho ámbito necesitan mantenerse actualizados, adaptando las recomendaciones a cada caso, educando a los pacientes y promoviendo el acceso equitativo a estas tecnologías. Pero la individualización sigue siendo lo principal: hay que elegir para cada paciente las herramientas más apropiadas y seguras según sus características particulares.

ABSTRACT

Introduction: traditional models for caring for patients with diabetes show structural limitations in the face of the sustained growth of healthcare demand. Artificial intelligence emerges here as a tool with real transformative capacity. It can process large amounts of clinical data, recognize patterns that escape conventional analysis, and suggest personalized recommendations, opening concrete possibilities to improve both patient outcomes and the efficiency of the healthcare system.

Materials and methods: a descriptive bibliographic search was conducted, focusing on: clinical practice guidelines, meta-analyses, systematic reviews, and controlled trials. Publications from the last five years were prioritized, and when it was necessary to support essential concepts, earlier sources were consulted. Focused on the applications of artificial intelligence that facilitate the physician's work in the daily management of diabetes.

Results: machine learning and deep learning systems have improved the functioning of automated insulin pumps, achieving more precise metabolic control. Evidence shows that artificial intelligence contributes to the early diagnosis of type 1, type 2, and gestational diabetes. It also helps predict chronic complications and personalize treatments. Continuous glucose monitors, smart insulin pens, data download platforms, and telemedicine are tools that help integrate all this information and maintain effective contact with the patient.

Conclusions: artificial intelligence in the field of diabetes is advancing rapidly. Professionals working in this area need to stay updated, adapting recommendations to each case, educating patients, and promoting equitable access to these technologies. But individualization remains the main priority: it is necessary to choose for each patient according to their particular characteristics.

Palabras clave: inteligencia artificial; aprendizaje automático; aprendizaje profundo; monitoreo continuo de glucosa; dosificación automática de insulina; lapiceras inteligentes; plataformas; telemedicina.

Key words: artificial intelligence; machine learning; deep learning; continuous glucose monitoring; automated insulin dosing; smart pens; platforms; telemedicine.

Revista de la Sociedad Argentina de Diabetes 2026; Vol. 60 (150-160)

Revista de la Sociedad Argentina de Diabetes 2026; Vol. 60 (150-160)

- ¹ Médica especialista Universitaria en Medicina Interna, especializada en Diabetes (Sociedad Argentina de Diabetes), trabajadora independiente, Clínica San Ramón, Chaco, Argentina
- ² Médico de Familia, especializado en Diabetes (Sociedad Argentina de Diabetes), Docente, Universidad Nacional de Cuyo, Director rotación Medicina Interna, Vicepresidente CEIS-OSEP, Mendoza, Argentina
- ³ Médica especialista en Clínica Médica, especializada en Diabetes (Sociedad Argentina de Diabetes), Secretaria del Comité de Graduados, Sociedad Argentina de Diabetes, Hospital Lencinas, Mendoza, Argentina
- ⁴ Magíster en Diabetes, Médica especialista en Clínica Médica y en Nutrición, especializada en Diabetes (Sociedad Argentina de Diabetes), *staff* Servicio de Diabetes, Hospital Universitario Austral, Pilar, Provincia de Buenos Aires, Argentina
- ⁵ Médica especialista en Medicina Interna, Nutrición y Diabetes (Universidad de Buenos Aires, UBA), miembro titular de la Sociedad Argentina de Diabetes, consultorio privado, Ciudad Autónoma de Buenos Aires, Argentina

- ⁶ Médico Generalista, especialista Universitario en Nutrición, especializado en Diabetes (Sociedad Argentina de Diabetes), Médico de Planta, Servicio de Endocrinología y Diabetes, Hospital Avellaneda, Tucumán, Argentina
- ⁷ Médica especialista en Clínica Médica, especializada en Diabetes (Sociedad Argentina de Diabetes), Hospital Escuela de Agudos Dr. Ramón Madariaga, Posadas, Misiones, Argentina
- ⁸ Doctor en Medicina, especialista en Medicina Interna, Director de la Maestría de Diabetología y Nutrición, Universidad Católica de Córdoba, Director General Clínica Universitaria Reina Fabiola, experto en Diabetes, Consejo Médico de Córdoba, Córdoba, Argentina

Contacto de la autora: Carolina Figueredo
E-mail: caropfigueredo@gmail.com
Fecha de trabajo recibido: 27/1/2026
Fecha de trabajo aceptado: 28/3/2026

Conflictos de interés: los autores declaran que no existe conflicto de interés.

INTRODUCCIÓN

La diabetes mellitus (DM) representa uno de los problemas más serios para la salud pública mundial. Su prevalencia sigue creciendo, y las complicaciones que conlleva son graves para los pacientes y costosas para los sistemas de salud. En este panorama, la inteligencia artificial (IA) aparece como un campo de la informática que ofrece sistemas capaces de razonar, aprender, reconocer patrones y ayudar en la toma de decisiones. En la DM específicamente, esta tecnología ha irrumpido con fuerza, mostrando un crecimiento acelerado y un potencial real para analizar datos complejos, permitir intervenciones a tiempo y ayudar a que los sistemas de salud funcionen mejor^{1,2}.

Los objetivos de este trabajo fueron: a) revisar el uso de la tecnología digital y cómo se integra con la IA en la práctica médica diaria en pacientes con DM; b) explorar su utilidad para anticipar diagnósticos, detectar complicaciones en forma temprana y personalizar tratamientos; c) estudiar los fundamentos del aprendizaje automático y profundo, el análisis predictivo de datos y los diversos algoritmos que se aplican a la dosificación automatizada de insulina; d) analizar el desarrollo actual y futuro de los sistemas de monitoreo continuo de

glucosa (MCG) y las nuevas lapiceras de insulina; e) evaluar la tecnología de descarga de datos y la telemedicina como herramientas para lograr comunicación efectiva con el paciente. Por su parte, el objetivo del análisis consistió en explicar cómo la IA es el motor que hace funcionar cada una de esas tecnologías.

MATERIALES Y MÉTODOS

Se realizó una revisión narrativa de tipo descriptiva centrada en la intersección entre la tecnología digital de uso en la DM y la IA. Se consultaron las bases de datos PubMed/MEDLINE, Google Scholar y SciELO. Los términos de búsqueda incluyeron combinaciones de "artificial intelligence," "machine learning," "diabetes technology," "automated insulin delivery," "deep learning," "continuous glucose monitoring," "smart pens," "platforms" y "telemedicine".

Los criterios de inclusión para la búsqueda fueron: artículos publicados entre enero de 2023 y noviembre de 2025 (para asegurar la máxima actualidad exigida), estudios que analicen la aplicación directa de algoritmos de IA en tecnología de uso frecuente en DM, guías de práctica clínica de sociedades internacionales (*American Diabetes Association*, Sociedad Argentina de Diabetes, So-

ciudad Española de Diabetes) metaanálisis y trabajos que incluyeran tecnologías con disponibilidad técnica y regulatoria en la Argentina, en inglés y español. Asimismo, se excluyeron reportes de casos aislados o series de casos con $n < 5$ pacientes, estudios que no involucraran el uso de tecnologías digitales o algoritmos de decisión, artículos de opinión o editoriales sin sustento en datos experimentales, tecnologías en fase experimental temprana (preclínica) sin perspectiva de aplicación en el corto plazo.

El contenido se debatió durante una jornada profesional. Se centró en temas de relevancia clínica práctica, los debates actuales y las áreas donde todavía no hay consenso. El proceso contó con la guía de un especialista que facilitó material de referencia, moderó el análisis de temas complejos y ayudó a refinar la presentación para que fuera más clara y aplicable al día a día.

Para la edición y síntesis del documento se utilizó la asistencia de la IA (Claude, Anthropic) como herramienta de apoyo editorial, sin que esta generara contenido científico original. El contenido sustantivo fue redactado íntegramente por los autores.

RESULTADOS

Aprendizaje automático y profundo en sistemas de infusión automatizada de insulina

El aprendizaje automático o *machine learning* (ML) es una rama de la IA que permite a las computadoras aprender directamente de los datos. En vez de programarlas para cada tarea específica, estas herramientas identifican patrones y hacen predicciones a partir de la información que procesan. El aprendizaje profundo o *deep learning* (DL) va un paso más allá: usa redes neuronales inspiradas en el cerebro humano, con muchas capas, para analizar grandes volúmenes de datos y detectar patrones complejos. Es particularmente útil para interpretar imágenes, voz y texto^{3,4}.

Los pacientes con DM1 enfrentan desafíos importantes para lograr un buen control glucémico. En los sistemas de administración automatizada de insulina (*automated insulin delivery*, AID), la IA actúa como el núcleo de decisión. Mediante el ML y el DL, el sistema no solo reacciona a la glucosa actual, sino que predice tendencias futuras para ajustar la infusión de forma proactiva, emulando la función pancreática, para optimizar el control metabólico y mejorar la calidad de vida⁴⁻⁶ (Figura 1).


Los sistemas de AID se clasifican según cuánto automatizan. Los de asa cerrada híbrida (*hybrid closed loop*, HCL) integran un monitor continuo de glucosa con un algoritmo que adapta las dosis de insulina mediante una bomba. Automatizan completamente el ajuste de la tasa basal y las correcciones entre comidas y durante la noche, pero el usuario todavía tiene que intervenir en las ingestas y en el ejercicio. Los de asa cerrada completa (*full closed loop*, FCL) automatizan todo, incluyendo los bolos para las comidas, sin que el paciente deba contar carbohidratos. Esto reduce notablemente la carga del manejo diario^{6,7}.

Los sistemas de HCL disponibles comercialmente usan tres tipos principales de algoritmos. Los algoritmos proporcional-integral-derivativo (PID) ajustan la insulina considerando la diferencia entre los niveles de glucosa medidos y el objetivo (componente proporcional), el área bajo la curva (componente integral) y la velocidad de cambio (componente derivativo). Los sistemas híbridos de asa cerrada, por ejemplo las series Minimed®, incorporaron una realimentación de insulina donde la infusión que calcula se reduce proporcionalmente según una estimación de cuánta insulina hay en plasma en ese momento⁶⁻⁸.

Los algoritmos de control predictivo basados en modelos (*model predictive control*, MPC) usan un modelo matemático para anticipar cómo va a fluctuar la glucosa. Predicen la trayectoria glucémica a corto plazo para ajustar la insulina, mantener los niveles dentro del rango objetivo y tener en cuenta la sensibilidad estimada del paciente a la insulina⁶⁻⁸.


Los algoritmos basados en lógica difusa (LD) modulan la insulina según reglas diseñadas para imitar el conocimiento y la experiencia de profesionales expertos. Su flexibilidad y tolerancia a la imprecisión los hace útiles para escenarios ambiguos, como variaciones por actividad física y eventos estresantes⁶⁻⁸.

La IA permitió un cambio fundamental: pasar del control glucémico reactivo al predictivo. Los sistemas de HCL actuales optimizan el control metabólico, reducen complicaciones y mejoran la calidad de vida. Con las nuevas tecnologías nos acercamos a sistemas de FCL capaces de personalizar modelos sin comprometer la privacidad del paciente, integrando datos de contexto, como ejercicio, sueño y cambios hormonales, para lograr una predicción y adaptación más robustas^{9,10} (Figura 2; Tablas 1 y 2)



DL: deep learning; AID: automated insulin delivery.

Figura 1: Aplicación del *deep learning* en sistemas de administración automatizada de insulina³.

Cam APS FX (CamDiab)	Control-IQ (Tandem)	DBLG1 (Diabeloop)	MiniMed 670G/780G (Medtronic)	Omnipod 5 (Insulet)	Sistema Nano Touch Medtrum
 DANA RS pump DANA-i pump YpsoPump	 Tandem t:slim X2 pump with algorithm Tandem Mobi pump with algorithm	 Kaleido pump	 MiniMed pump with algorithm	 Omnipod 5 pump with algorithm	 Nano pump
 Libre 3 Dexcom G6	 Libre 2 plus Dexcom G6 Dexcom G7	 Dexcom G6	 Guardian 3 Guardian 4	 Libre 2 plus Dexcom G6	 Nano CGM
 MPC adaptativo	 MPC con algoritmos basados en reglas y adaptativo	 MPC adaptativo	 PID y LD con feedback de insulina adaptativa	 Algoritmo MPC adaptativo	 Algoritmo MPC adaptativo y pancreático GO

Diseño propio del equipo de autores. Adaptado de referencia 9.

Figura 2: Principales sistemas automatizados de insulina disponibles comercialmente.

Características	Sistema Nano Touch Medtrum®	Medtronic® 780 G
Algoritmo y enfoque	Algoritmo MPC específico APGO: algoritmo pancreático GO. Reseteo del algoritmo a medianoche según lo ocurrido los últimos 30 y 7 días y las últimas 24 h	Algoritmo PID y LD con <i>feedback</i> de insulina adaptativa con límites del modelo y autocorrecciones basadas en reglas
Aprendizaje del algoritmo	Ajusta automáticamente la administración de insulina según tendencias de glucosa, lecturas secuenciales del MCG y la IOB. Modo auto <i>meal</i> : utiliza el RIC aprendido y el RIC configurado; tiene en cuenta la insulina activa administrada previamente	Basado en DDT y en estimación de glucosa en ayunas e insulinemia en el momento de la determinación de la glucosa en ayunas
Glucosa objetivo	Objetivos personalizables: 100 (por defecto) /110/120 mg/dl Objetivo de ejercicio: 150 mg/dl	Fija: 100 mg/dl (por defecto). Personalizable: 110 o 120 mg/dl. Objetivo de ejercicio: 150 mg/dl
Suministro de insulina basal	Ajuste automatizado acorde al sensor y al historial de administración de insulina cada 2 minutos	Según el algoritmo, ajustada cada 5-10 minutos según datos de MCG en tiempo real
Bolos de corrección automatizados	Administración al predecir que la glucosa alcanzará un valor 150 mg/dl Autobolo de comida: en respuesta a fluctuaciones del sensor de glucosa luego del anuncio de una ingesta, sin realizar conteo de hidratos de carbono exacto, administrando insulina según el RIC aprendido. Bolo manual: se aplicará llegando al objetivo seteado para el paciente	Tiene como objetivo 120 mg/dl una vez que la insulina basal alcanza el máximo, independientemente del objetivo configurado. Bolos de corrección basados en parámetros de control del algoritmo no programados por el usuario. Se suprime durante un objetivo temporal
Parámetros de seguridad	Algoritmo se detiene automáticamente: 1. Cuando no hay lecturas del sensor por 3 h Error del transmisor o batería agotada (<i>warm up</i> del sensor, señal del sensor perdida, calibración necesaria, sensor expirado, sensor con falla) 2. Insulina máxima administrada en 8 h 3. Insulina mínima administrada en 5 h	Dosis máxima de insulina horaria Dosis máxima de insulina en 4 h Insulina basal mínima durante 24 h Dosis máxima de bolo. Insulina basal mínima durante 3-6 h
Parámetros que el usuario/ profesional pueden modificar	En modo automático: objetivo de autobasal, y del bolo, RIC, FSI, TIA	RIC, TIA, objetivo de glucosa para el algoritmo

MPC: model predictive control; PID: algoritmos proporcional-integral-derivativo; LD: lógica difusa; IOB: insulina a bordo; RIC: ratio insulina-hidratos de carbono (*insulin-to-carbohydrate ratio*); TIA: tiempo de insulina activa; MCG: monitoreo continuo de glucosa; FSI: factor de sensibilidad a la insulina; DDT: dosis diaria total.

Diseño propio del equipo de los autores. Adaptado de referencia 6.

Tabla 1: Características de los sistemas de administración automatizada de insulina comercializados en la Argentina.

Características	Cam APS/FX®	Diabeloop®	Control-IQ®	Omnipod 5®
Algoritmo y enfoque	Algoritmo MPC adaptativo ajustando RIC, FSI y TIA, en un teléfono inteligente desbloqueado	Algoritmo MPC adaptativo, integrado a <i>Smartphone</i> /dispositivo portátil	MPC con algoritmos basados en reglas y adaptativo a tasa basal preprogramada y factores de corrección. Ubicado en infusora	Algoritmo MPC adaptativo controlado desde la infusora o una aplicación móvil
Aprendizaje del algoritmo	Basado en DDT y peso. Se adapta a patrones diarios, prandiales y circadianos; independiente de parámetros basales y de sensibilidad programados	Ajuste periódico del modelo según el comportamiento del paciente a partir de datos de últimas horas: DDT, peso, tasa basal, contenido de HdeC en comida principal	Basado en DDT, peso, RIC, tasa basal, factor de corrección	Basado en DDT, actualizado con cada cambio de Pod (cada 3 días)
Glucosa objetivo	Fija: 104 mg/dl (por defecto); personalizable entre 80- 200 mg/dl. Modo de actividad opcional.	Fija: 110 mg/dl (por defecto) con rango 100-130 mg/dl Zen-mode: 20-40 mg/dl superior al objetivo actual para evitar hipoglucemias No tiene modo ejercicio (anunciarlo)	Rango objetivo fijo: 112,5-160 mg/dl Nocturno intensificado: 112,5-120 mg/dl Ejercicio: 140-160 mg/dl Autocorrección: 110 mg/dl	Objetivo: personalizable: 110 mg/dl-150 mg/dl en incrementos de 10 mg/dl Objetivo de actividad opcional: 150 mg/dl
Suministro de insulina basal	Según el algoritmo, ajustada cada 5-10 minutos según datos del MCG en tiempo real	Según el algoritmo, ajustada cada 5-10 minutos según datos de MCG en tiempo real	Según el algoritmo, ajustada cada 5-10 minutos según datos del MCG en tiempo real: Disminuye basal si predicción en 30 minutos es <112,5 mg/dl y lo detiene si predicción a 30 minutos es <70 mg/dl	Según el algoritmo, ajustada cada 5-10 minutos según datos del MCG en tiempo real
Bolos de corrección automatizados	Bolos de corrección automatizados con tasa basal más agresiva Opción "Boost" (capacidad del usuario para aumentar temporalmente administración de insulina) Bolos de corrección manuales según parámetros de sensibilidad programados.	Si no tiene sistema de detección de comidas, deben anunciarse; si puede dejarse predefinido contenido habitual de HdeC en ingestas principales	60% de la dosis de corrección calculada si se predice que la glucosa excede 180 mg/dl, con objetivo de 110 mg/dl. Bolos de corrección manuales opcionales, también con objetivo de 110 mg/dl	Bolos de corrección automáticos mediante ajustes más agresivos de la tasa basal. Bolos de corrección manuales opcionales
Parámetros de seguridad	Dosis máxima de insulina en 2 h, dosis mínima de insulina en 1,5 h	Agresividad variable. Bolo para una comida determinada: modular en incrementos de $\pm 10\%$. Alerta para rescate de HdeC Límite de infusión máxima de insulina	Administración máxima de insulina en 2 h Administración máxima de insulina en 24 h Cantidad máxima de bolo	Cantidad máxima de insulina administrada individualmente en cualquier momento. Cantidad máxima de bolo
Parámetros que el usuario/ profesional pueden modificar	Objetivo de glucosa, RIC, FSI, Modo <i>boost</i> o <i>ease off</i> (más o menos agresivo)	Objetivo de glucosa del sistema, DDT, RIC, reactividad del algoritmo al tratamiento (agresividad)	Tasas basales de insulina, RIC, FSI, objetivo de glucosa temporal, modo sueño TIA no se modifica (seteada en 5 h)	RIC, FSI (bolos del usuario), TIA (bolos del usuario) Glucosa objetivo para algoritmo Glucosa objetivo durante ejercicio con administración atenuada de insulina

MPC: *model predictive control*; IOB: *insulina a bordo*; RIC: *ratio insulina-hidratos de carbono (insulin-to-carbohydrate ratio)*; HdeC: *hidratos de carbono*; TIA: *tiempo de insulina activa*; MCG: *monitoreo continuo de glucosa*; FSI: *factor de sensibilidad a la insulina*; DDT: *dosis diaria total*; MCG: *monitoreo continuo de glucosa*.

Diseño propio del equipo de los autores. Adaptado de referencia 6 y 9.

Tabla 2: Características de los sistemas de administración automatizada de insulina comercializados en el mundo.

Análisis predictivo en la atención del paciente con diabetes

El análisis predictivo basado en la IA en diabetología abarca tres dimensiones que vale la pena explorar^{11,12}.

La primera se centra en predecir riesgo y hacer diagnósticos tempranos. Aquí el objetivo es identificar quienes tienen más probabilidades de desarrollar DM2, DM1 o DM gestacional (DMG). En DM2, varios algoritmos (como XGBoost, Random Forest, Support Vector Machine y redes neuronales convolucionales) mostraron ser más robustos y confiables que los modelos tradicionales. Usan variables como edad, índice de masa corporal, glucemia, genes y hábitos de vida para hacer sus predicciones^{13,14}. En DMG, la IA se enfoca en la predicción temprana, algo vital no solo para los resultados del bebé, sino también por el riesgo futuro, tanto para las madres como para los hijos, de desarrollar DM2 y problemas cardiovasculares¹⁵.

La segunda dimensión se relaciona con predecir complicaciones microvasculares y macrovasculares. En retinopatía diabética, algoritmos como IDx-DR (aprobado por la *Food and Drug Administration*, FDA) y Eye Art se entrenan con miles de imágenes y aprenden a reconocer patrones de daño precoz con buena precisión diagnóstica. Pueden establecer la probabilidad de retinopatía diabética severa, lo que permite intervenir antes de que se produzca pérdida de la visión^{16,17}. En nefropatía diabética, modelos de aprendizaje profundo que integran imágenes de retina y datos de monitores de glucosa han mostrado que cuando hay retinopatía y proteinuria juntas, se puede predecir el daño renal con más precisión¹⁸. Para las complicaciones macrovasculares, modelos como XGBoost y varias redes neuronales han sido mejores que los métodos convencionales para predecir el riesgo de accidente cerebrovascular, enfermedad cardiovascular y enfermedad vascular periférica¹⁹.

La tercera dimensión es la optimización del tratamiento. Incluye tanto el pronóstico de glucemia para los sistemas de asa cerrada como la personalización de regímenes terapéuticos. Para pacientes con DM2, en 2024, la FDA aprobó Omnipod 5®, que en un estudio de 26 semanas redujo la HbA1c en 1,6% y aumentó el tiempo en rango en 22,4%, sin más hipoglucemia²⁰. Usar *big data* combinado con aprendizaje automático facilita analizar registros médicos, datos genómicos y de sensores para personalizar los tratamientos²¹.

Pero estos avances también traen desafíos. Se necesitan procesos sólidos de aprobación regulatoria, estándares para garantizar que los datos sean de calidad, normativas estrictas de protección de datos y un marco legal que diga claramente quién es responsable cuando hay errores algorítmicos. La IA explicable busca reducir la desconfianza hacia estos sistemas mostrando de manera transparente qué factores influyeron en cada predicción^{22,23}.

Sistemas de monitoreo continuo de glucosa: desarrollo actual y futuro

El MCG ha cambiado profundamente el manejo de la DM. Al brindar datos glucémicos continuos y dinámicos, estos sistemas superan ampliamente las limitaciones de la glucemia capilar tradicional. El estándar actual recomienda su uso para pacientes con DM1 y DM2 que usan insulina^{24,25}.

Hay dos sistemas diferentes. Los de lectura en tiempo real (rtMCG) dan lecturas automáticas cada 1-5 minutos que se mandan a un receptor, *smartphone* o bomba de insulina; tienen alertas y alarmas predictivas que avisan al usuario sobre tendencias glucémicas problemáticas. Por su parte, los de escaneo intermitente (iMCG o *Flash*) miden la glucosa continuamente, pero solo registran y muestran los datos cuando el usuario escanea el sensor con su lector, y no tienen alarmas automáticas^{25,26}.

Estos dispositivos miden la glucosa en el líquido intersticial. Hay un retraso natural, el *lag time*, de unos 5-15 minutos entre los niveles de glucosa en sangre y en el fluido intersticial. Para compensar esto se han desarrollado algoritmos predictivos de IA que filtran el "ruido" de la señal intersticial. La precisión se evalúa con la diferencia relativa absoluta media (*mean absolute relative difference*, MARD). Se trata de un promedio de todas las mediciones pareadas de MCG-referencia de todos los sensores utilizados en un estudio, en todos los participantes, en todo el rango de medición y durante toda la vida útil del sensor. El uso del MARD como la métrica más significativa para la precisión clínica de los sensores está muy extendido en el ámbito de la tecnología para la DM. Se define que un MARD menor al 10% es excelente, entre 10-14% es bueno y mayor a 14% es limitado^{26,27}. Sin embargo, hay algunas limitaciones importantes. El uso del MARD puede enmascarar la prevalencia y la magnitud de valores atípicos que pueden surgir debido a un control de fabricación inadecuado, la

variabilidad interindividual (p. ej., por reacciones a cuerpos extraños), un rendimiento subóptimo del sensor en ciertos rangos de glucosa e inconsistencias en la precisión durante el período de uso del sensor (p. ej., el rendimiento del día 1 frente al de los días posteriores). El uso del MARD o la correlación entre los datos del MCG y los del medidor de glucosa de referencia, como única fuente para la evaluación de la precisión, subestima considerablemente la información que proporciona el MCG sobre el proceso de fluctuación de la glucosa²⁷.

En situaciones de hipoglucemia, la precisión del MARD es sumamente importante en clínica desde el punto de vista de la seguridad. Aunque se incluyen en las solicitudes regulatorias, rara vez se publican o se discuten en presentaciones en congresos científicos. Es importante destacar que, dado que una precisión <70 mg/dL es baja para todos los sensores, el MARD global puede verse muy influenciado por el porcentaje de mediciones derivadas del rango hipoglucémico que se utiliza en su cálculo. Un porcentaje mayor en el rango hipoglucémico puede deberse al diseño del estudio (p. ej., la forma en que se reali-

zan las pruebas de hipoglucemia durante el estudio). Cuanto mayor sea el porcentaje de puntos en el rango hipoglucémico, mayor será la probabilidad de que el MARD global sea más preciso²⁷.

La evolución ha sido notable. Las primeras generaciones (1999-2006) necesitaban calibraciones diarias y tenían un MARD de 15-20%. Los dispositivos actuales de cuarta generación (2023-presente) no necesitan calibración, tienen bajo MARD y duran desde 10 hasta 365 días. El futuro va hacia más integración tecnológica, miniaturización, sensores de larga duración menos invasivos, y sistemas que integren el monitor de glucosa con sensores de cetonas^{28,29} (Tabla 3).

El tiempo en rango (*time in range*, TIR) es el porcentaje de tiempo que la glucosa está entre 70-180 mg/dL. Pero el tiempo en rango estrecho (*time in tight range* [TITR], de 70-140 mg/dL) refleja mejor los valores de glucosa normal y es preferible en pacientes con objetivos de control estricto, como embarazadas y niños con larga expectativa de vida. En DM1, un TITR mayor al 50% puede ser una meta razonable y segura^{30,31}.

Sistema	MARD	Duración	Calibración	Alarmas
Dexcom G7®	8,2-9,1%	10 días	No	Sí
FreeStyle Libre 3®	7,9%	14 días	No	Sí
Guardian 4/Simplera®	10,6%	7 días	No	Sí
Eversense E3/365®	8,5-9,1%	180-365 días	Sí	Sí
GSI Sibionics®	8,83%	14 días	No	Sí

MARD: mean absolute relative difference.

Tabla 3: Sistemas de monitoreo continuo de glucosa disponibles.

Lapiceras inteligentes de insulina

Las lapiceras inteligentes de insulina (*smart insulin pens*, SIPs) son dispositivos médicos con sensores y conectividad *bluetooth* que simplifican bastante el manejo de la DM. Demostraron ser efectivas para el problema de mala adherencia terapéutica que afecta aproximadamente a la mitad de los usuarios de insulina^{32,33}. Estos dispositivos utilizan algoritmos para calcular dosis de corrección y predecir el impacto de la insulina activa, transformando una lapicera convencional en una herramienta de precisión para prevenir errores humanos.

Existen dos categorías principales: las lapiceras inteligentes reutilizables integradas funcionan como una unidad completa de inyección y necesitan cartuchos compatibles específicos (InPen de Medtronic® y NovoPen 6 de Novo Nordisk®) y los capuchones inteligentes que se ponen sobre

las lapiceras prellenadas convencionales (Bigfoot Unity® y Mallya®)³⁴.

Algunos grupos de pacientes se benefician particularmente: los niños y adolescentes, porque se pueden compartir datos con médicos y padres para la supervisión remota; y los pacientes con DM2 que comienzan tratamiento con insulina, especialmente adultos mayores o personas con dificultades cognitivas, que encuentran en estas lapiceras un buen apoyo para el día a día. Aquellos que tienen mala adherencia también se benefician, porque el registro automático elimina los olvidos de dosis, mientras que quienes presentan mucha variabilidad glucémica sin explicación clara pueden identificar mejor qué está pasando^{35,36}.

Usar lapiceras inteligentes con MCG, lo que se llama *Smart MDI*, se asocia con mejoras importantes del control metabólico. Esta combinación integra

datos de glucosa en tiempo real con el registro de dosis de insulina. El aumento del tiempo en rango se debe principalmente a que hay menos bolos omitidos. Las lapiceras inteligentes, al integrar datos como carbohidratos, insulina activa, glucemia actual y registro de dosis y tiempo, ofrecen un sistema de seguridad eficaz para reducir el error humano^{37,38}.

Tecnología de descarga de datos y plataformas

El potencial de los datos en DM es enorme, pero la realidad es que la mayoría está subutilizada. La tecnología de descarga de datos (TDD) incluye los sistemas y procesos que permiten recolectar, transferir, almacenar y analizar de forma estructurada datos glucémicos, de dosis de insulina y de actividad física. Estos datos se pasan desde dispositivos portátiles a plataformas digitales para uso clínico y autogestión^{39,40}.

La barrera principal es lograr que haya interoperabilidad universal entre dispositivos y los *software* de diferentes fabricantes. Esto permitiría que los productos se comuniquen entre sí sin importar la marca, facilitando una visión integrada del control del paciente. Las plataformas ideales deberían tener compatibilidad con muchos dispositivos, descarga fácil y rápida, acceso para todo el equipo de salud, visualización dinámica de parámetros y cumplimiento estricto de estándares de seguridad y privacidad⁴¹.

Las plataformas propietarias como Dexcom Clarity®, LibreView® y CareLink® ofrecen una buena experiencia para sus dispositivos, pero limitan la visión completa de pacientes que usan tecnologías mixtas. Las plataformas agregadoras independientes, como Glooko® y Tidepool®, responden al desafío de la fragmentación juntando datos de diferentes fabricantes en una sola interfaz⁴².

Glooko® prioriza la integración con historias clínicas electrónicas mediante APIs, permitiendo transferencia automatizada y segura de datos a los registros médicos; Tidepool® se distingue por su misión de interoperabilidad abierta, ofreciendo Tidepool Loop®, la primera *App* de dosificación automatizada totalmente interoperable aprobada por la FDA. Ambas cumplen con estándares de seguridad y privacidad^{43,44}. En efecto, la IA actúa como un filtro inteligente en las plataformas integradoras (como Glooko® o Tidepool®), identificando patrones de riesgo (hipoglucemias inadvertidas o variabilidad extrema) entre miles de pacientes, lo que permite que el profesional priorice a quienes requieren intervención inmediata.

Telemedicina en diabetes

La Organización Mundial de la Salud (OMS) define la telemedicina como un servicio médico donde se usan diferentes tecnologías de comunicación para compartir información necesaria para diagnóstico, terapia y prevención de enfermedades. Tiene beneficios especiales en enfermedades crónicas como la DM⁴⁵.

Hay que distinguir entre diferentes modalidades: a) la teleconsulta es la interacción sincrónica entre el profesional y el paciente por videoconferencia, teléfono o plataformas digitales; implica comunicación bidireccional que permite la evaluación clínica, el ajuste de tratamiento y la educación; b) la telemetría es la transmisión automática de datos biomédicos desde dispositivos a sistemas de registro; es unidireccional; c) el telemonitoreo combina la telemetría con supervisión activa del equipo de salud, que revisa los datos regularmente y puede intervenir de manera proactiva^{46,47}.

En DM1, varias revisiones sistemáticas muestran mejoras significativas en la HbA1c cuando la telemedicina se usa como complemento del tratamiento estándar. Los beneficios son especialmente claros en niños y adolescentes⁴⁸. En DM2, varios metaanálisis reportan reducciones de la HbA1c de 0,31-0,33% con intervenciones de telemedicina, más beneficios en accesibilidad y menos tiempos de espera^{49,50}. En la DMG, la evidencia sobre el impacto metabólico es menos concluyente en desenlaces principales como peso al nacer, aunque claramente aumenta la satisfacción y adherencia de las pacientes⁵¹. En la prevención de la DM2, las intervenciones de la telemedicina enfocadas en la actividad física y la alimentación muestran resultados significativos: reducción de peso corporal (-1,66 kg), índice de masa corporal (-0.71 kg/m²) y circunferencia de cintura (-2,82 cm)⁵².

La telemedicina es sin dudas una herramienta complementaria valiosa, pero hay que reconocer que la evidencia de impacto metabólico todavía no es concluyente, principalmente por la alta heterogeneidad de los estudios y su corta duración. Es fundamental usar *softwares* validados y con protección adecuada de datos. La integración de la IA con la telemedicina permite el apoyo a la toma de decisiones en tiempo real, mejorando los resultados clínicos al proporcionar información basada en datos durante las consultas virtuales⁵³.

DISCUSIÓN

Esta revisión muestra que la IA dejó de ser una promesa futura para convertirse en una realidad

clínica concreta en el manejo de la DM. Los sistemas AID probablemente sean el avance más importante en el tratamiento de la DM1 en las últimas décadas. Evolucionaron desde controladores reactivos simples hasta algoritmos predictivos sofisticados capaces de anticipar excursiones glucémicas, permitiendo alcanzar tiempos en rango superiores al 70% en estudios de la vida real^{9,10}.

La capacidad de la IA para predecir el riesgo y diagnóstico temprano representa un verdadero cambio de paradigma en la medicina preventiva. Sin embargo, es necesario mantener una mirada crítica: la mayoría de estos modelos se entrenaron en poblaciones de países de altos ingresos, lo que plantea si funcionarán igual en poblaciones con características étnicas y socioeconómicas diferentes. En retinopatía diabética, los algoritmos han logrado sensibilidades superiores al 90%, lo que favorece el tamizaje de la población en riesgo^{16,17}.

El MCG evolucionó hacia dispositivos de cuarta generación, con MARD inferior al 10% y duraciones de hasta 365 días. En este contexto, se recomienda mantener una perspectiva crítica sobre el MARD como métrica única, porque puede ocultar imprecisiones en rangos específicos donde la precisión es más crítica para la toma de decisiones clínicas. La introducción del TITR es un refinamiento importante, ya que es más sensible para detectar excursiones glucémicas en pacientes con control estricto^{30,31}.

Las lapiceras inteligentes abordan el problema crítico de la adherencia que afecta aproximadamente a la mitad de los usuarios de insulina. El concepto de *Smart MDI* mostró mejoría del control metabólico comparable a sistemas de asa cerrada híbrida en poblaciones seleccionadas; sin embargo, el costo inicial y la necesidad de saber usar tecnología digital restringen el acceso. Además, la tecnología por sí sola no garantiza mejores resultados sin una base sólida de educación diabetológica y apoyo profesional continuo^{37,38}.

El advenimiento de un gran número de dispositivos conectados generó paradójicamente una sobrecarga de información cuando no se maneja de manera óptima. El desafío actual no es generar datos, sino integrarlos efectivamente y traducirlos en decisiones clínicas que se puedan implementar. Plataformas agregadoras como Glooko® y Tidepool® son respuestas importantes a este desafío, aunque persisten barreras técnicas y regulatorias^{39,44}.

Los avances en la IA plantean preguntas éticas y legales complejas que merecen cuidadosa atención. La responsabilidad cuando hay error algorítmico

no tiene respuesta legal clara en la mayoría de las jurisdicciones. El sesgo algorítmico es otra preocupación fundamental: los algoritmos aprenden de datos que, si no representan a poblaciones diversas, van a perpetuar y posiblemente amplificar las disparidades existentes en salud. El costo es una barrera crítica al acceso equitativo, con sistemas de cobertura que frecuentemente quedan atrás respecto de la evidencia científica disponible^{22,23}.

CONCLUSIONES

El escenario digital actual exige que se incorporen competencias específicas en el accionar diario de los profesionales sanitarios. Primero, se necesita desarrollar alfabetización digital y capacidad de analizar *big data*, que incluye manejar adecuadamente los grandes volúmenes de datos que generan los dispositivos conectados. Segundo, es fundamental adquirir comprensión algorítmica para interpretar críticamente las recomendaciones que generan estos sistemas; esta comprensión ayudará a diferenciar entre una recomendación algorítmica favorable y una situación que necesita un juicio clínico más amplio, considerando situaciones particulares del paciente como otras enfermedades o factores psicosociales relevantes^{54,55}.

Los profesionales de la salud tienen una responsabilidad múltiple que va más allá de usar estas tecnologías: necesitan mantenerse constantemente actualizados sobre los avances, desarrollar nuevas competencias digitales, evaluar críticamente la evidencia disponible, individualizar cuidadosamente las recomendaciones para cada paciente, educar al respecto, y abogar activamente por políticas que garanticen acceso equitativo a estas herramientas.

El futuro de la diabetología será digital e inteligente, sin dudas, pero tiene que permanecer fundamentalmente humano, centrado en la persona con DM y guiado por los principios éticos, que son el fundamento mismo de la medicina.

BIBLIOGRAFÍA

1. Rani KMJ. Diabetes prediction using machine learning. *Int J Sci Res Comp Sci Eng InfTech*. 2020;6(4):295-305.
2. Ellahham S. Artificial intelligence: the future for diabetes care. *Am J Med*. 2020;133(8):895-900.
3. Corrao S, Janić M, Maggio V, Rizzo M. Machine learning and deep learning in diabetology. *Front Clin Diabetes Healthc*. 2025;6:1547689.
4. Beneyto A, Contreras I, Vehi Y. Inteligencia artificial y diabetes. *Rev Soc Esp Diabetes*. 2023.
5. Enes-Romero P, Güemes M, Guijo B, Martos-Moreno GÁ, et al. Automated insulin delivery systems in the treatment of diabetes. *Endocrinol Diabetes Nutr*. 2024;71(10):436-46.

6. Phillip M, Nimri R, Bergenstal RM, Barnard-Kelly, et al. Consensus recommendations for the use of automated insulin delivery technologies. *Endocr Rev.* 2023;44(2):254-80.
7. Boughton CK, Hovorka R. New closed-loop insulin systems. *Diabetologia.* 2021;64(5):1007-15.
8. Vibora PIB, Fernández K, Carril NA, Curieses NP. Guía de uso de sistemas de asa cerrada 2025. Grupo GTTAD-SED; 2025. Disponible en: https://www.sediabetes.org/wp-content/uploads/GTTAD_GUIA_SAC_2025_vF.pdf.
9. Kadiyala N, Hovorka R, Boughton CK. Closed-loop systems: recent advancements. *Expert Rev Med Devices.* 2024;21(10):927-41.
10. Boughton CK, Hovorka R. The role of automated insulin delivery technology in diabetes. *Diabetologia.* 2024;67(10):2034-44.
11. Guan Z, Li H, Liu R, Cai C, et al. Artificial intelligence in diabetes management. *Cell Rep Med.* 2023;4(10):101213.
12. Kiran M, Xie Y, Anjum N, Ball G, et al. Machine learning and AI in type 2 diabetes prediction. *Front Digit Health.* 2025;7:1557467.
13. Khokhar PB, Gravino C, Palomba F. Advances in AI for diabetes prediction. *Artif Intell Med.* 2025;164:103132.
14. Mittal R, Weiss MB, Rendon A, Shafazand S, et al. Machine learning for early detection of type 1 diabetes. *Int J Mol Sci.* 2025;26(9):3935.
15. AlSaad R, Elhenidy A, Tabassum A, Odeh N, et al. Artificial intelligence in gestational diabetes care. *J Diabetes Sci Technol.* 2025.
16. Sobhi N, Sadeghi-Bazargani Y, Mirzaei M, Abdollahi M, et al. AI for early detection of diabetes mellitus complications. *J Diabetes Metab Disord.* 2025;24(1):104.
17. Yang Q, Bee YM, Lim CC, Sabanayagam C, et al. Use of AI with retinal imaging in screening for diabetes-associated complications. *EClinicalMedicine.* 2025;81:103089.
18. Dai C, Sun X, Xu J, Chen M, et al. Machine learning in prediction of diabetic kidney Disease. *Int J Med Inform.* 2025;202:105975.
19. Nur A, Tjandra S, Yunnanisha DA, Keane A, et al. Predicting cardiovascular risks in type 2 diabetes with AI. *Narra J.* 2025;5(1):e2116.
20. Davis GM, Peters AL, Bode BW, Carlson AL, et al. Glycaemic outcomes with Omnipod 5 in type 2 diabetes. *Diabetes Obes Metab.* 2025;27(1):143-54.
21. Sen A, Mohanraj PS, Laxmi V, Ashique S, et al. AI-based treatment strategy in type 2 diabetes. *J Pharm Anal.* 2025;15(6):101305.
22. Rosenbacke R, Melhus A, McKee M, Stuckler D. Explainable AI in health care. *JMIR AI.* 2024;3:e53207.
23. Gala KM. Ethical and legal considerations in AI-driven health. *Int J Sci Res Comp Sci Eng InfTech.* 2024;10(5):682-90.
24. American Diabetes Association. *Diabetes Technology: Standards of Care 2025.* *Diabetes Care.* 2024;48(Suppl 1):S146-66.
25. Yoo JH, Kim JH. Advances in continuous glucose monitoring. *Diabetes Metab J.* 2023;47(1):27-41.
26. Kwon SY, Moon JS. Advances in CGM: clinical applications. *Endocrinol Metab.* 2025;40(2):161-73.
27. Fishman S, editor. *Advances in diabetes technology.* Cham (CH): Springer; 2025. (Contemporary Endocrinology). doi:10.1007/978-3-031-75352-7.
28. Bender C, Vestergaard O, Cichosz SL. The history, evolution and future of CGM. *Diabetologia.* 2025;68(3):17. doi: 10.3390/diabetologia6030017
29. Kong YW, Morrison D, Lu JC, Lee MH, et al. Continuous ketone monitoring. *Diabetes Obes Metab.* 2024;26(Suppl 7):47-58.
30. Battelino T, Danne T, Bergenstal RM, Amiel SA, et al. Clinical Targets for CGM Data Interpretation. *Diabetes Care.* 2019;42(8):1593-603.
31. American Diabetes Association. *Diabetes Technology: Standards of Care 2026.* *Diabetes Care.* 2025;49(Suppl 1):S150-65.
32. Boonpattharatthiti K, Saenook T, Neelapaijit N, Sakunrag I, et al. Adherence to insulin therapy. *Res Social Adm Pharm.* 2024;20(3):255-95.
33. Lingen K, Pikounis T, Bellini N, Isaacs D, et al. Connected insulin pens in diabetes management. *Endocr Connect.* 2023;12(11):e230108.
34. Tejera-Pérez C, Chico A, Azriel-Mira S, Lardiés-Sánchez B, et al. Connected insulin pens: expert recommendation. *Diabetes Ther.* 2023;14(7):1077-91.
35. Ramírez-Mendoza F, González JE, Gasca E, Camacho M, et al. Time in range with multidisciplinary program in pediatric diabetes. *Pediatr Diabetes.* 2020;21(1):61-68.
36. Sy SL, Munshi MM, Toschi E. Can smart pens help improve diabetes management? *J Diabetes Sci Technol.* 2022;16(3):628-34.
37. Adolffson P, Björnsson V, Hartvig NV, Kaas A, et al. Improved glycemic control with smart insulin pens. *Diabetes Ther.* 2022;13(1):43-56.
38. MacLeod J, Vigersky RA. Precision insulin management with smart insulin pens. *J Diabetes Sci Technol.* 2023;17(2):283-9.
39. Mackenzie SC, Sainsbury CAR, Wake DJ. Diabetes and AI beyond the closed loop. *Diabetologia.* 2024;67(2):223-35.
40. Arbiter B, Look H, McComb L, Snider C. Why download data: benefits and challenges. *Diabetes Spectr.* 2019;32(3):221-5.
41. Akturk HK, Bindal A. Advances in diabetes technology within the digital ecosystem. *J Manag Care Spec Pharm.* 2024;30(10-b Suppl):S7-20.
42. Sociedad Española de Diabetes. Manual de telemedicina y diabetes. Disponible en: www.sediabetes.org.
43. Wong JC, Izadi Z, Schroeder S, Nader M, et al. Software platform for diabetes device data. *Diabetes Technol Ther.* 2018;20(12):806-16.
44. Eberle C, Stichling S, Löhnert M. *Diabetology 4.0: Digitalization insights.* *J Med Internet Res.* 2021;23(3):e23475.
45. Dhediya R, Chadha M, Bhattacharya AD, Godbole S, et al. Role of telemedicine in diabetes management. *J Diabetes Sci Technol.* 2023;17(3):775-81.
46. Verhoeven F, Van Gemert-Pijnen L, Dijkstra K, Nijland N, et al. Teleconsultation and videoconferencing in diabetes care. *J Med Internet Res.* 2007;9(5):e37.
47. Marcolino MS, Oliveira JAQ, D'Agostino M, Ribeiro AL, et al. Impact of mHealth Interventions. *JMIR Mhealth Uhealth.* 2018;6(1):e23.
48. Zhang K, Huang Q, Wang Q, Li C, et al. Telemedicine in glycemic control in children with T1DM. *J Med Internet Res.* 2024;26:e51538.
49. Hangaard S, Laursen SH, Andersen JD, Kronborg T, et al. Effectiveness of telemedicine for type 2 diabetes. *J Diabetes Sci Technol.* 2023;17(3):794-825.
50. Dat TV, Binh V, Hoang TM, Tu VL, et al. Effectiveness of telemedicine in type 2 diabetes. *Sage Open Medicine.* 2024;12.
51. Laursen SH, Boel L, Udsen FW, Secher PH, et al. Telemedicine in managing diabetes in pregnancy. *J Diabetes Sci Technol.* 2023;17(5):1364-75.
52. Suhlrie L, Ayyagari R, Mba C, Olsson K, et al. Telemedicine in prevention of type 2 diabetes. *Diabetes Metab Syndr.* 2025;19(5):103252.
53. Pérez K, Wisniewski D, Ari A, Lee K, et al. Investigation into application of AI and telemedicine in rural communities. A systematic literature review. *Healthcare (Basel).* 2025 Feb 4;13(3):324. doi: 10.3390/healthcare13030324. PMID: 39942513; PMCID: PMC11816903.
54. Montero-Delgado JA, Merino Alonso FJ, Monte Boquet E, Ávila de Tomás JF, et al. Competencias digitales de profesionales sanitarios. *Educ Med.* 2019;21(5):338-44. doi: 10.1016/j.edumed.2019.02.010
55. Puchades R, Ramos-Ruperto L, en nombre del Grupo de Trabajo de Medicina Digital de la SEMI. Artificial intelligence in clinical practice. *Rev Clin Esp.* 2025;225(1):23-7.