

ARTÍCULO DE REVISIÓN

Medicina

La transformación de la práctica cardiológica por la inteligencia artificial: Desde el cribado clínico hasta la toma de decisiones personalizadas

Héctor Adrián Franco^{1,2}, María Paz Fleitas Acosta¹, Luciano Javier Zarate Mercado¹, Wyder Dario Pacce Mallorquín¹, Ruth Estefania Mallorquin Ortellado¹, Jonathan Salinas¹, Vinicius da Silva Souza³, Lígia Maria Oliveira de Souza⁴

¹Facultad de Ciencias de la Salud, Universidad Nacional del Este, Ciudad del Este, Paraguay; ²Facultad de Ciencias de la Salud, Universidad del Sol, filial Ciudad del Este, Paraguay; ³Facultad de Ciencias Médicas, Universidad Privada del Este, filial Ciudad del Este, Paraguay; ⁴Facultad de Ciencias de la Salud, Universidad Politécnica y Artística del Paraguay, filial Ciudad del Este, Paraguay.

Enviado: 14 de marzo de 2025

Aceptado: 20 de mayo de 2025

Publicado: 18 de junio de 2025

DOI: [10.5281/zenodo.17887328](https://doi.org/10.5281/zenodo.17887328)



Licencia Creative Commons Atribución 4.0 Internacional (CC-BY)

RESUMEN

Introducción: La práctica cardiológica contemporánea enfrenta limitaciones humanas inherentes, como la variabilidad interobservador y la inercia terapéutica, en un contexto de creciente demanda asistencial. La inteligencia artificial (IA) emerge como un paradigma disruptivo capaz de redefinir el continuo de atención, desde el cribado hasta la medicina de precisión. Esta revisión integrativa analiza el impacto clínico, pronóstico y ético de la IA en la cardiología moderna. **Materiales y métodos:** Se realizó una revisión integrativa siguiendo el marco de Whittemore y Knafl. Se llevó a cabo una búsqueda sistemática en PubMed, Scopus y Google Scholar de estudios publicados entre 2019 y 2025. Se incluyeron investigaciones originales y revisiones sistemáticas sobre aprendizaje automático (*machine learning*) y aprendizaje profundo (*deep learning*) aplicados al diagnóstico, pronóstico y tratamiento cardiovascular. **Resultados:** Los algoritmos de IA en dispositivos ponibles (*wearables*) alcanzan una sensibilidad del 99,6 % para la detección de fibrilación auricular, facilitando el

Autor correspondiente: Lígia Maria Oliveira de Souza. Facultad de Ciencias de la Salud, Universidad Politécnica y Artística del Paraguay, filial Ciudad del Este, Paraguay

Correo electrónico: ligiamaria2107@gmail.com

Financiación: Los autores no recibieron fondos externos para la realización de este estudio.

Conflictos de interés: Los autores declaran no tener conflictos de interés financieros, personales, profesionales, institucionales ni de otra índole relacionados con este trabajo.

cribado masivo. En el ámbito pronóstico, los modelos de aprendizaje automático superan a los scores tradicionales (Framingham/SCORE), elevando el índice-C de 0,61 a 0,68 en la predicción de eventos adversos mayores (MACE). Asimismo, la automatización en imagenología (RMN/TC) y el fenotipado digital optimizan la precisión diagnóstica y la personalización terapéutica. Persisten barreras críticas, destacando la opacidad de los algoritmos tipo «caja negra» y el riesgo de sesgos algorítmicos en poblaciones subrepresentadas. **Conclusiones:** La IA no reemplaza al cardiólogo, sino que instaura una era de «inteligencia aumentada» que potencia la precisión diagnóstica y la estratificación del riesgo. La transición hacia la práctica clínica rutinaria requiere superar desafíos de explicabilidad, validar modelos en poblaciones diversas para mitigar sesgos y garantizar la interoperabilidad de los sistemas.

Palabras clave: inteligencia artificial, cardiología, aprendizaje automático, medicina de precisión, sesgo algorítmico, sistemas de apoyo a la decisión clínica

INTRODUCCIÓN

Las enfermedades cardiovasculares (ECV) se mantienen como la principal causa de morbilidad y mortalidad a nivel mundial, presentando un desafío creciente para los sistemas de salud que deben gestionar volúmenes de datos clínicos sin precedentes. La práctica cardiológica contemporánea, tradicionalmente fundamentada en la interpretación humana de signos clínicos y estudios de imagen, se enfrenta a limitaciones inherentes como la variabilidad interobservador, la fatiga diagnóstica y la inercia terapéutica, fenómeno que impide la intensificación oportuna del tratamiento pese a no alcanzar los objetivos clínicos (1, 2). En este contexto, la inteligencia artificial (IA), y específicamente los subcampos de aprendizaje automático (machine learning) y aprendizaje profundo (deep learning), ha emergido no como una mera herramienta auxiliar, sino como un vector de transformación paradigmática que promete redefinir la cadena de valor asistencial (3).

La evolución de la capacidad computacional ha permitido transitar de modelos de predicción de riesgo estáticos y poblacionales, como el score de Framingham, a modelos dinámicos y personalizados capaces de procesar variables no lineales complejas, superando en precisión predictiva a las puntuaciones tradicionales (4, 5). Actualmente, la literatura sugiere que la integración de algoritmos de IA puede optimizar desde el cribado de arritmias mediante dispositivos ponibles (wearables) — con sensibilidades superiores al 99% reportadas en entornos controlados— (6) hasta la segmentación auto-

matizada en modalidades de imagen multimodales, reduciendo significativamente los tiempos de flujo de trabajo y mejorando la sensibilidad diagnóstica (7, 8). Sin embargo, a pesar de la robustez técnica reportada, la traslación clínica de estas tecnologías enfrenta barreras críticas. Entre ellas destacan la opacidad de los algoritmos tipo «caja negra» (black box), que dificulta la confianza médica y la explicabilidad del diagnóstico (9, 10), así como preocupaciones éticas sustanciales sobre sesgos algorítmicos derivados del entrenamiento en poblaciones no representativas, lo que podría exacerbar las inequidades en salud (11, 12).

A diferencia de revisiones previas centradas en modalidades aisladas, la presente revisión integrativa adopta un enfoque holístico del «viaje del paciente». Se examina la evidencia actual sobre cómo la IA está reconfigurando la cardiología en tres dominios críticos: (1) la precisión diagnóstica y el cribado temprano, (2) la estratificación de riesgo y pronóstico, y (3) la personalización terapéutica y la toma de decisiones. El objetivo es sintetizar los hallazgos más recientes (2019-2025) para dilucidar no solo la eficacia clínica de estas herramientas, sino también las implicaciones prácticas necesarias para su adopción generalizada.

MATERIALES Y MÉTODOS

Esta revisión integrativa se desarrolló siguiendo el marco metodológico propuesto por Whitemore y Knafl, el cual permite la inclusión de estudios con diversas metodologías (experimentales y no experimentales) para

proporcionar una comprensión completa del fenómeno de interés. El proceso se estructuró en cinco etapas: identificación del problema, búsqueda de literatura, evaluación de datos, análisis de datos y presentación.

Estrategia de búsqueda y fuentes de información

Se llevó a cabo una búsqueda bibliográfica exhaustiva y sistemática de artículos publicados principalmente entre enero de 2019 y mayo de 2025, con el fin de capturar los avances más recientes en algoritmos de aprendizaje profundo (Deep Learning) y modelos de lenguaje masivo. No obstante, se incluyeron estudios seminales seleccionados a partir de 2016 cuando aportaban validaciones fundamentales de las tecnologías discutidas.

Las bases de datos consultadas incluyeron PubMed/MEDLINE, Scopus y Google Scholar. Para garantizar la exhaustividad, se utilizaron combinaciones de términos MeSH (Medical Subject Headings) y palabras clave en inglés, interconectados mediante los operadores booleanos «AND» y «OR». Las cadenas de búsqueda se adaptaron a la sintaxis de cada base de datos, basándose en la siguiente lógica:

1. **Dominio tecnológico:** “Artificial Intelligence” OR “Machine Learning” OR “Deep Learning” OR “Neural Networks” OR “Natural Language Processing”.
2. **Dominio clínico:** “Cardiology” OR “Cardiovascular Diseases” OR “Atrial Fibrillation” OR “Heart Failure” OR “Ischemia”.
3. **Dominio de aplicación:** “Screening” OR “Wearables” OR “Risk Prediction” OR “Decision Support Systems” OR “Pharmacogenomics” OR “Health Equity”.

Criterios de elegibilidad

Para asegurar la relevancia y calidad de la evidencia, se aplicaron los siguientes criterios de inclusión y exclusión:

Criterios de inclusión

1. Artículos originales, ensayos clínicos aleatorizados, estudios de cohortes y revisiones sistemáticas con o sin metanálisis.
2. Estudios realizados en poblaciones humanas adultas (mayores de 18 años).
3. Publicaciones que reportaran métricas de rendimiento claras (sensibilidad, especificidad, AUC, valor predictivo) o resultados clínicos tangibles

(reducción de mortalidad, reingresos, adherencia a guías).

4. Artículos disponibles en idioma inglés o español.

Criterios de exclusión

1. Editoriales, cartas al editor y opiniones de expertos sin datos empíricos.
2. Estudios *in silico* puramente técnicos sin validación clínica externa o conjuntos de datos del mundo real.
3. Estudios en modelos animales, salvo aquellos fundamentales para explicar mecanismos fisiopatológicos emergentes en imagenología experimental.

Selección de estudios y extracción de datos

La selección se realizó en dos fases. Primero, se cribaron títulos y resúmenes para eliminar duplicados y artículos irrelevantes. Segundo, se leyeron los textos completos de los artículos preseleccionados para verificar el cumplimiento de los criterios de elegibilidad. La extracción de datos se sistematizó utilizando una matriz predefinida que capturó:

1. Autor y año de publicación.
2. Objetivo del estudio.
3. Diseño metodológico y tamaño de la muestra.
4. Tipo de algoritmo de IA utilizado.
5. Hallazgos principales y métricas de rendimiento.
6. Limitaciones reportadas (ej. sesgos de datos, falta de validación externa).

Síntesis y análisis de datos

Dada la heterogeneidad metodológica de los estudios incluidos (que abarcan desde validaciones de software hasta análisis éticos), no fue posible realizar un metanálisis cuantitativo global. En su lugar, se optó por una síntesis narrativa temática. Los hallazgos se agruparon, codificaron y organizaron en cuatro categorías lógicas que reflejan el flujo de la práctica clínica:

1. **Cribado y diagnóstico de precisión:** enfocado en wearables e imagenología multimodal.
2. **Pronóstico y estratificación de riesgo:** comparación de Machine Learning vs. scores tradicionales.
3. **Terapéutica personalizada:** farmacogenómica y sistemas de soporte a la decisión (CDSS).
4. **Desafíos de implementación:** Barreras económicas, flujo de trabajo, interpretabilidad (Black Box) y ética (sesgos).

Esta estructura permitió contrastar resultados, identificar patrones consistentes y señalar lagunas en la evidencia actual.

RESULTADOS

La revisión de la literatura seleccionada permite identificar cuatro áreas temáticas principales donde la inteligencia artificial ha demostrado un impacto clínico tangible: (1) Diagnóstico y cribado de precisión, (2) Estratificación de riesgo, (3) Personalización terapéutica y (4) Desafíos de implementación. A continuación, se detallan los hallazgos para cada dominio.

Diagnóstico de precisión: de los dispositivos ponibles a la imagenología multimodal

La transformación diagnóstica impulsada por la IA se manifiesta en dos frentes complementarios: la masificación del cribado de arritmias mediante dispositivos ponibles (wearables) y la automatización del análisis de imagen cardíaca compleja.

Detección de arritmias y monitoreo ambulatorio

La integración de algoritmos de IA en dispositivos ponibles y parches de salud móvil (mHealth) ha permitido transitar de un monitoreo episódico a uno continuo, facilitando la recolección de datos fisiológicos extensos. La evidencia actual indica que estos algoritmos alcanzan una precisión diagnóstica comparable a los métodos estándar de electrocardiograma (ECG) para la detección de fibrilación auricular (FA). Específicamente, estudios recientes reportan que los algoritmos aplicados a parches de monitoreo continuo pueden lograr una sensibilidad del 99,6% y una especificidad del 98,0%, métricas que sugieren una capacidad robusta para el cribado poblacional (6).

Dispositivos de consumo masivo, como pulseras inteligentes equipadas con algoritmos validados, también han demostrado una eficacia significativa en la identificación de episodios de FA frente a los métodos tradicionales (13). Además, la utilidad de estas herramientas se extiende a la detección de isquemia silente, donde el uso de ECG de 12 derivadas enriquecido con IA durante el ritmo sinusal ha mostrado potencial para mejorar la precisión diagnóstica (14, 15). Sin embargo, la literatura enfatiza consistentemente que, pese a su alta sensibilidad, estas tecnologías deben considerarse herramientas adjuntas. Los diagnósticos definitivos aún requieren confirmación mediante registros de ECG estándar,

especialmente para descartar falsos positivos derivados de artefactos de movimiento (16, 17).

Automatización en imagenología cardíaca (ecocardiografía, RMN y TC)

En el entorno clínico, el aprendizaje profundo (Deep Learning) ha abordado uno de los cuellos de botella más críticos de la cardiología: la segmentación y cuantificación de estructuras cardíacas.

1. **Ecocardiografía:** La aplicación de redes neuronales ha permitido automatizar la delimitación de estructuras anatómicas y la cuantificación de la función ventricular izquierda con alta precisión (18). Estos modelos no solo aceleran el flujo de trabajo al reducir la necesidad de segmentación manual —propensa a la variabilidad interobservador—, sino que también mejoran la detectabilidad de fenotipos complejos como la hipertrofia ventricular y optimizan la interpretabilidad global del estudio (19, 20).
2. **Resonancia magnética cardíaca (RMN):** Los algoritmos de aprendizaje profundo han logrado cuantificaciones totalmente automatizadas de los volúmenes ventriculares con una fidelidad que minimiza la variabilidad entre observadores (7). Estudios recientes destacan la capacidad de estos modelos para realizar segmentaciones fiables en estudios de cine-RMN provenientes de múltiples proveedores, lo que refuerza su aplicabilidad en escenarios clínicos diversos (21).
3. **Tomografía computarizada (TC):** La innovación en TC incluye enfoques totalmente automatizados para el cálculo del score de calcio (Agatston) y la segmentación multiorgánica (8). Estos avances superan a los métodos tradicionales basados en atlas al eliminar la necesidad de co-registros de datos complejos, optimizando así el análisis volumétrico para la evaluación de la enfermedad coronaria (22).

En conjunto, la evidencia sugiere que la sinergia entre la automatización por IA y la supervisión clínica no solo mejora la eficiencia operativa, sino que eleva la sensibilidad diagnóstica al detectar cambios morfológicos sutiles que podrían pasar desapercibidos en una evaluación visual convencional.

Pronóstico y estratificación de riesgo: superioridad algorítmica y fenotipado digital

El segundo dominio crítico donde la inteligencia artificial está transformando la práctica clínica es la predic-

ción de eventos adversos y la caracterización fenotípica de enfermedades complejas, desplazando progresivamente a los modelos de riesgo lineales tradicionales.

Superioridad predictiva sobre scores tradicionales (MACE y muerte súbita)

La estratificación del riesgo cardiovascular ha dependido históricamente de puntuaciones estáticas como Framingham o SCORE. Sin embargo, la literatura reciente sugiere que los modelos de aprendizaje automático (Machine Learning, ML) superan consistentemente a estas herramientas convencionales al integrar variables no lineales y biomarcadores complejos. Por ejemplo, Kolossváry et al. demostraron que los modelos de ML alcanzaron un índice-C de 0,68 para la predicción de eventos cardiovasculares adversos mayores (MACE), una mejora sustancial frente al 0,61 obtenido por los scores clásicos en cohortes similares (4).

En la misma línea, Tamarappoo et al. evidenciaron que la integración algorítmica de biomarcadores circulantes y de imagen proporciona perfiles de riesgo más granulares y precisos que el Framingham Risk Score (5). Esta superioridad se extiende a escenarios agudos y posinfarto. Tian et al. reportaron que la combinación de ML con la escala GRACE mejora significativamente la predicción de MACE a largo plazo en comparación con el uso aislado de la escala GRACE, lo que sugiere que la IA puede actuar como un potenciador de las herramientas clínicas existentes (23).

Asimismo, en la predicción de muerte súbita cardíaca y eventos arrítmicos, modelos avanzados basados en transformers y supervivencia han demostrado métricas de discriminación superiores a los enfoques convencionales (24). No obstante, es crucial notar que, aunque el rendimiento in silico es alto, estudios como el de Balado et al. advierten sobre la necesidad imperiosa de validación externa en poblaciones diversas antes de una implementación clínica generalizada (25).

Refinamiento del fenotipado en insuficiencia cardíaca y gestión de reingresos

La IA está abordando la complejidad inherente de la insuficiencia cardíaca (IC) mejorando la distinción entre fenotipos (IC con fracción de eyección reducida vs. preservada) y optimizando la gestión hospitalaria. Oo et al. destacaron que el uso de procesamiento de lenguaje natural (NLP) combinado con IA sobre historias clínicas electrónicas (HCE) permite una extracción de subtipos

de IC y parámetros ecocardiográficos significativamente más precisa que la dependencia exclusiva de los códigos CIE-10, los cuales carecen de especificidad clínica (26). Este fenotipado de precisión es fundamental para la implementación de terapias dirigidas (27).

En cuanto a la gestión operativa, los algoritmos predictivos alimentados por datos masivos de HCE han mostrado utilidad para prever reingresos hospitalarios, un indicador clave de calidad asistencial. Mortazavi et al. reportaron un estadístico-c promedio de 0,63 para la predicción de hospitalizaciones (28), demostrando la capacidad de estos modelos para identificar pacientes de alto riesgo que los modelos tradicionales podrían pasar por alto (29). Más recientemente, modelos desarrollados por Weller et al. (2025) y Kwon et al. (2019) han logrado predecir con éxito la mortalidad a 90 días y el riesgo de reingreso integrando datos demográficos, clínicos y de laboratorio, facilitando así intervenciones preventivas personalizadas (30, 31).

Terapéutica personalizada y toma de decisiones: del intervencionismo a la farmacogenómica

La inteligencia artificial no solo ha redefinido el diagnóstico, sino que ha comenzado a optimizar la ejecución terapéutica, influyendo tanto en procedimientos invasivos de alta complejidad como en la prescripción farmacológica de precisión y la adherencia a guías clínicas.

Navegación en tiempo real y planificación intervencionista (TAVI, PCI y electrofisiología)

En cardiología intervencionista, la IA ha demostrado un impacto clínico sustancial al mejorar la selección de pacientes y la precisión procedimental. En el contexto del implante de válvula aórtica transcatheter (TAVI), la integración de algoritmos con tomografía computarizada (TC) pre-procedimental ha optimizado significativamente el dimensionamiento y posicionamiento de la prótesis, minimizando complicaciones críticas como las fugas paravalvulares (32).

Asimismo, el uso de software automatizado durante el procedimiento permite una guía de imagen en tiempo real, facilitando ajustes intraoperatorios basados en la anatomía específica del paciente (33). Para la intervención coronaria percutánea (PCI), la planificación asistida por IA mediante angio-TC ha mejorado la detección de enfermedad coronaria relevante antes de la intervención (34). Además, la combinación de IA con imágenes intravasculares (IVUS) optimiza la colocación de stents

con una precisión superior a la angiografía convencional, correlacionándose con mejores resultados clínicos (35).

En el campo de la electrofisiología, los sistemas de navegación en tiempo real impulsados por IA procesan electrogramas con mayor rapidez y exactitud que los métodos tradicionales, permitiendo un mapeo más preciso para la ablación de arritmias y reduciendo las tasas de recurrencia (36, 37).

Convergencia de IA y farmacogenómica: hacia la dosis de precisión

La fusión de la IA con la farmacogenómica representa un avance hacia la medicina de precisión, permitiendo adaptar la selección y dosificación de fármacos al perfil genético individual para minimizar eventos adversos. Algoritmos avanzados pueden analizar polimorfismos en enzimas metabolizadoras, como el CYP450, para informar decisiones de dosificación en fármacos con estrecho margen terapéutico, una práctica vital en el manejo de la hipertensión y la anticoagulación (38, 39).

Además, sistemas de IA dedicados a la farmacovigilancia y análisis geoespacial están facilitando la estratificación del riesgo de toxicidad farmacológica, como la cardiotoxicidad asociada a fluoroquinolonas, identificando pacientes vulnerables antes de la exposición al fármaco (40). La capacidad de estos sistemas para integrar datos genéticos y clínicos permite también la identificación preventiva de interacciones fármaco-fármaco (DDIs) peligrosas, reduciendo la probabilidad de resultados cardiovasculares severos (41, 42).

Sistemas de soporte a la decisión (CDSS) y reducción de la inercia terapéutica

Finalmente, la implementación de Sistemas de Soporte a la Decisión Clínica (CDSS) basados en IA ha mostrado ser eficaz para combatir la inercia terapéutica y mejorar la adherencia a las guías de práctica clínica. Revisiones sistemáticas confirman que estos sistemas, al proporcionar alertas en tiempo real y recomendaciones basadas en evidencia, incrementan el cumplimiento de los protocolos de manejo en enfermedades crónicas (43,44).

En el manejo de la hipertensión y la insuficiencia cardíaca, los CDSS actúan impulsando a los clínicos a iniciar o intensificar terapias de manera oportuna cuando no se alcanzan las metas terapéuticas, superando barreras conductuales del médico (1, 2). Esta asistencia automatizada no solo estandariza la calidad de la atención, sino

que optimiza la selección de medicamentos en escenarios complejos (45).

Desafíos de implementación: la «caja negra», inequidad algorítmica y barreras sistémicas

A pesar de la eficacia técnica descrita, la adopción generalizada de la IA en cardiología enfrenta obstáculos críticos que trascienden el rendimiento algorítmico. La literatura identifica tres barreras fundamentales: la opacidad de los modelos, los sesgos éticos y las limitaciones económicas y operativas.

El dilema de la «caja negra» y la confianza médica

La naturaleza opaca de los modelos de aprendizaje profundo (Deep Learning), a menudo denominados «cajas negras», representa un obstáculo significativo para la confianza médica. La incapacidad de estos algoritmos para explicitar la lógica detrás de una predicción genera escepticismo e incertidumbre entre los clínicos, lo que limita su integración en flujos de trabajo donde la seguridad del paciente es primordial (9, 10).

Para mitigar esto, el campo de la Inteligencia Artificial Explicable (XAI) ha propuesto soluciones técnicas: métodos como LIME (Local Interpretable Model-Agnostic Explanations) permiten aproximar explicaciones locales para predicciones individuales (46), mientras que enfoques basados en la teoría de juegos, como SHAP (SHapley Additive exPlanations), cuantifican la contribución de cada variable al resultado final (47). Adicionalmente, el uso de mapas de calor visuales (p. ej., Grad-CAM) en radiología y ecocardiografía ayuda a los médicos a validar qué regiones anatómicas influyeron en la decisión del algoritmo (48), y el uso de modelos sustitutos (surrogate models) simplifica algoritmos complejos para hacerlos inteligibles (49).

Sesgos algorítmicos e inequidad en salud

Una preocupación ética central es la perpetuación de inequidades en salud debido a sesgos en los datos de entrenamiento. La evidencia señala que los modelos entrenados en poblaciones no representativas sufren de falta de generalización y pueden fallar en subgrupos demográficos específicos. Por ejemplo, Puyol-Antón et al. documentaron discrepancias significativas en el rendimiento de segmentación de resonancia magnética (RMN) entre grupos raciales, evidenciando métricas inferiores para ciertas minorías (11).

De igual forma, herramientas de detección de arritmias pueden fallar al reconocer patrones en condiciones poco frecuentes si estas están subrepresentadas en los datos (12). Estos sesgos no solo reducen la precisión clínica, sino que exacerban disparidades sistémicas (50, 51). Las estrategias de mitigación propuestas incluyen la diversificación activa de los conjuntos de datos (52) y la implementación de auditorías de equidad mediante herramientas como Aequitas para monitorear el desempeño del modelo a través de diferentes subpoblaciones (53, 54).

Barreras económicas y de flujo de trabajo

Finalmente, la viabilidad práctica de la IA se ve obstaculizada por factores económicos y organizacionales. Los altos costos iniciales de infraestructura y la incertidumbre sobre el retorno de inversión (ROI) disuaden a muchas instituciones de salud de adoptar estas tecnologías. Además, la integración de herramientas de IA en los sistemas de registro electrónico de salud (EHR) existentes presenta desafíos de interoperabilidad costosos.

A nivel operativo, la disrupción de los flujos de trabajo establecidos y la necesidad de capacitación especializada generan resistencia entre los profesionales, quienes pueden percibir estas herramientas como una carga de tiempo adicional o una amenaza a su autonomía clínica. Superar estas barreras requiere demostrar valor clínico y económico tangible, así como desarrollar interfaces interoperables que se integren sin fricción en la práctica diaria.

DISCUSIÓN

La presente revisión integrativa confirma que la cardiología se encuentra en un punto de inflexión histórico, transitando de un modelo basado en la evidencia poblacional y la interpretación visual subjetiva, a uno fundamentado en la medicina de precisión y el análisis de datos masivos. Los hallazgos sintetizados sugieren que la inteligencia artificial (IA) no es simplemente una mejora incremental de las herramientas existentes, sino una tecnología disruptiva que redefine la jerarquía del conocimiento médico, permitiendo superar las limitaciones cognitivas humanas como la fatiga y la variabilidad interobservador. La capacidad de los algoritmos de aprendizaje profundo para automatizar la segmentación en resonancia magnética (RMN) y ecocardiografía con alta fidelidad libera al especialista de tareas repetitivas,

permitiéndole centrarse en la interpretación clínica de alto nivel (7, 19).

Sin embargo, esta evolución tecnológica presenta dualidades que deben ser gestionadas con cautela clínica. Por un lado, emerge una paradoja en el cribado ambulatorio: la alta sensibilidad de los dispositivos ponibles —reportada hasta en un 99,6% para la detección de fibrilación auricular (6)— conlleva el riesgo inherente de generar falsos positivos derivados de artefactos de movimiento. Esto subraya que la IA en esta etapa no debe interpretarse como una herramienta diagnóstica autónoma, sino como un sistema de triaje avanzado que requiere, obligatoriamente, la confirmación mediante métodos estándar como el ECG de 12 derivadas (17).

En el dominio del pronóstico, se observa la obsolescencia progresiva de los scores de riesgo lineales, como Framingham o SCORE, frente a los modelos de Machine Learning (ML). Dado que la biología cardiovascular es intrínsecamente compleja y no lineal, los modelos algorítmicos que integran múltiples variables logran una discriminación superior. Kolossváry et al. demostraron que los modelos de ML pueden alcanzar un índice-C de 0,68 en la predicción de eventos adversos mayores (MACE), superando significativamente el 0,61 obtenido por puntuaciones clásicas en cohortes comparables (4). Asimismo, Tamarappoo et al. evidenciaron que la integración de biomarcadores de imagen y circulantes mediante IA proporciona perfiles de riesgo más granulares y específicos para el paciente que las herramientas tradicionales (5).

Más allá del riesgo numérico, la IA permite un «fenotipado profundo». La capacidad de procesar lenguaje natural (NLP) de las historias clínicas ha permitido identificar subtipos de insuficiencia cardíaca que los sistemas de codificación tradicionales (CIE-10) omiten, facilitando una personalización terapéutica real (26). Esto implica que el futuro de la cardiología no reside solo en tratar la enfermedad diagnosticada, sino en predecir y prevenir la descompensación mediante el análisis de datos masivos antes de que ocurra. La implementación clínica enfrenta un obstáculo epistemológico mayor: el problema de la «caja negra».

La confianza médica se erosiona cuando el algoritmo no puede explicar su razonamiento, un factor crítico cuando se toman decisiones de vida o muerte. Según Hicks et al. y Zeineldin et al., la falta de transparencia genera escepticismo entre los profesionales (9, 10). Aunque técnicas de inteligencia artificial explicable (XAI) como

LIME y SHAP ofrecen aproximaciones matemáticas para interpretar las predicciones (46, 47), la literatura sugiere que la interpretabilidad debe ser un requisito de diseño a priori para garantizar la seguridad del paciente.

Asimismo, la revisión ilumina una crisis de equidad latente. Los algoritmos entrenados en cohortes homogéneas no solo fallan en generalizar, sino que pueden sesgar activamente el diagnóstico en contra de minorías raciales. Puyol-Antón et al. documentaron discrepancias significativas en el rendimiento de segmentación de RMN entre grupos raciales, evidenciando métricas inferiores para minorías (11). Esto plantea un imperativo ético destacado por Vardas et al. y Jones: la validación de la IA no debe medirse solo por su precisión global, sino por su equidad a través de diversos subgrupos demográficos (12, 50).

Es necesario reconocer las limitaciones de este trabajo. La heterogeneidad metodológica de los estudios incluidos impidió la realización de un metanálisis cuantitativo global. Además, dada la velocidad exponencial de desarrollo en IA, algunos algoritmos evaluados al inicio del periodo de búsqueda pueden haber sido superados por nuevas arquitecturas, lo que sugiere una rápida obsolescencia de la evidencia técnica si no se actualiza continuamente.

En cuanto a las fortalezas de esta revisión, destaca su enfoque holístico que abarca todo el «viaje del paciente», integrando dominios que usualmente se estudian de forma aislada, como el cribado ambulatorio, la imagenología compleja, la farmacogenómica y la ética algorítmica. Esta perspectiva integradora permite identificar sinergias entre tecnologías dispares y ofrecer una visión sistémica de la transformación cardiológica.

En conclusión, la transformación de la práctica cardiológica por la inteligencia artificial es inminente y multifacética. La evidencia actual respalda la integración de la IA como una herramienta de «inteligencia aumentada» que potencia las capacidades humanas en el cribado de arritmias, la precisión de la imagenología multimodal y la estratificación dinámica del riesgo cardiovascular. Sin embargo, para transitar de la validación in silico a la adopción clínica rutinaria, es imperativo exigir pruebas rigurosas en poblaciones diversas para mitigar los sesgos algorítmicos y garantizar la equidad en salud (25, 55). Asimismo, se debe priorizar la implementación de modelos que ofrezcan transparencia en su toma de decisiones para fomentar la confianza médica y desarrollar interfaces interoperables que reduzcan las barreras de

flujo de trabajo. El cardiólogo del futuro no será reemplazado por la IA, sino que evolucionará hacia un rol de integrador de datos, utilizando estos algoritmos para ofrecer una medicina más precisa, preventiva y personalizada.

REFERENCIAS

1. Ahmed MM, Okesanya OJ, Olaleke NO, Adigun OA, Adebayo UO, Oso TA, et al. Integrating digital health innovations to achieve universal health coverage: Promoting health outcomes and quality through global public health equity. *Healthcare (Basel)*. 2025;13(9):1060. doi: [10.3390/healthcare13091060](https://doi.org/10.3390/healthcare13091060)
2. Song J, Wang X, Wang B, Gao Y, Liu J, Zhang H, et al. Effectiveness of a clinical decision support system for hypertension management in primary care: study protocol for a pragmatic cluster-randomized controlled trial. *Trials*. 2022;23(1):412. doi: [10.1186/s13063-022-06374-x](https://doi.org/10.1186/s13063-022-06374-x)
3. Antoun I, Abdelrazik A, Eldesouky M, Li X, Layton GR, Zakkar M, et al. Artificial intelligence in atrial fibrillation: emerging applications, research directions and ethical considerations. *Front Cardiovasc Med*. 2025;12:1596574. doi: [10.3389/fcvm.2025.1596574](https://doi.org/10.3389/fcvm.2025.1596574)
4. Kolossváry M, Sereti I, Zanni MV, Fichtenbaum CJ, Aberg JA, Bloomfield GS, et al. Statin-dependent and -independent pathways are associated with major adverse cardiovascular events in people with HIV. *J Clin Invest*. 2025;135(22). doi: [10.1172/jci196021](https://doi.org/10.1172/jci196021)
5. Tamarappoo BK, Lin A, Commandeur F, McElhinney PA, Cadet S, Goeller M, et al. Machine learning integration of circulating and imaging biomarkers for explainable patientspecific prediction of cardiac events: A prospective study. *Atherosclerosis*. 2021;318:76–82. doi: [10.1016/j.atherosclerosis.2020.11.008](https://doi.org/10.1016/j.atherosclerosis.2020.11.008)
6. Santala OE, Lipponen JA, Jäntti H, Rissanen TT, Tarvainen MP, Laitinen TP, et al. Continuous mHealth patch monitoring for the algorithm-based detection of atrial fibrillation: Feasibility and diagnostic accuracy study. *JMIR Cardio*. 2022;6(1):e31230. doi: [10.2196/31230](https://doi.org/10.2196/31230)
7. Böttcher B, Beller E, Busse A, Cantré D, Yücel S, Öner A, et al. Fully automated quantification of left ventricular volumes and function in cardiac MRI: clinical evaluation of a deep learning-based algorithm. *Int J Cardiovasc Imaging*. 2020;36(11):2239–47. doi: [10.1007/s10554-020-01935-0](https://doi.org/10.1007/s10554-020-01935-0)
8. Gautam A, Raghav P, Subramaniam V, Kumar S, Kumar S, Jain D, et al. Fully automated Agatston score calculation from electrocardiography-gated cardiac computed tomography using deep learning and multi-organ segmentation: A validation study. *Angiology*. 2025;76(5):431–40. doi: [10.1177/00033197231225286](https://doi.org/10.1177/00033197231225286)

9. Hicks SA, Isaksen JL, Thambawita V, Ghouse J, Ahlberg G, Linneberg A, et al. Explaining deep neural networks for knowledge discovery in electrocardiogram analysis. *Sci Rep*. 2021;11(1):10949. doi: [10.1038/s41598-021-90285-5](https://doi.org/10.1038/s41598-021-90285-5)
10. Zeineldin RA, Karar ME, Elshaer Z, Coburger J, Wirtz CR, Burgert O, et al. Explainable hybrid vision transformers and convolutional network for multimodal glioma segmentation in brain MRI. *Sci Rep*. 2024;14(1):3713. doi: [10.1038/s41598-024-54186-7](https://doi.org/10.1038/s41598-024-54186-7)
11. Puyol-Antón E, Ruijsink B, Mariscal Harana J, Piechnik SK, Neubauer S, Petersen SE, et al. Fairness in cardiac magnetic resonance imaging: Assessing sex and racial bias in deep learning-based segmentation. *Front Cardiovasc Med*. 2022;9(859310):859310. doi: [10.3389/fcvm.2022.859310](https://doi.org/10.3389/fcvm.2022.859310)
12. Vardas EP, Marketou M, Vardas PE. Medicine, healthcare and the AI act: gaps, challenges and future implications. *Eur Heart J Digit Health*. 2025;6(4):833–9. doi: [10.1093/ehjdh/ztaf041](https://doi.org/10.1093/ehjdh/ztaf041)
13. Chen E, Jiang J, Su R, Gao M, Zhu S, Zhou J, et al. A new smart wristband equipped with an artificial intelligence algorithm to detect atrial fibrillation. *Heart Rhythm*. 2020;17(5 Pt B):847–53. doi: [10.1016/j.hrthm.2020.01.034](https://doi.org/10.1016/j.hrthm.2020.01.034)
14. Baek YS, Kwon S, You SC, Lee KN, Yu HT, Lee SR, et al. Artificial intelligence-enhanced 12-lead electrocardiography for identifying atrial fibrillation during sinus rhythm (AIAFib) trial: protocol for a multicenter retrospective study. *Front Cardiovasc Med*. 2023;10:1258167. doi: [10.3389/fcvm.2023.1258167](https://doi.org/10.3389/fcvm.2023.1258167)
15. Khalifa A, Abdulaziz M, Parvez SS, Salem A, Panhwer HS, Saleem U, et al. The digital revolution in cardiac ischemia: Artificial intelligence (AI)-enhanced detection, diagnosis, and risk stratification. *Cureus*. 2025;17(10):e95059. doi: [10.7759/cureus.95059](https://doi.org/10.7759/cureus.95059)
16. Giebel GD, Gissel C. Accuracy of mHealth devices for atrial fibrillation screening: Systematic Review. *JMIR MHealth UHealth*. 2019;7(6):e13641. doi: [10.2196/13641](https://doi.org/10.2196/13641)
17. Hartikainen S, Lipponen JA, Hiltunen P, Rissanen TT, Kolk I, Tarvainen MP, et al. Effectiveness of the chest strap electrocardiogram to detect atrial fibrillation. *Am J Cardiol*. 2019;123(10):1643–8. doi: [10.1016/j.amjcard.2019.02.028](https://doi.org/10.1016/j.amjcard.2019.02.028)
18. Duffy G, Cheng PP, Yuan N, He B, Kwan AC, Shun-Shin MJ, et al. High-throughput precision phenotyping of left ventricular hypertrophy with cardiovascular deep learning. *JAMA Cardiol*. 2022;7(4):386–95. doi: [10.1001/jamacardio.2021.6059](https://doi.org/10.1001/jamacardio.2021.6059)
19. Maturi B, Dulal S, Sayana SB, Ibrahim A, Ramakrishna M, Chinta V, et al. Revolutionizing cardiology: The role of artificial intelligence in echocardiography. *J Clin Med*. 2025;14(2):625. doi: [10.3390/jcm14020625](https://doi.org/10.3390/jcm14020625)
20. Ghorbani A, Ouyang D, Abid A, He B, Chen JH, Harrington RA, et al. Deep learning interpretation of echocardiograms. *NPJ Digit Med*. 2020;3(1):10. doi: [10.1038/s41746-019-0216-8](https://doi.org/10.1038/s41746-019-0216-8)
21. Wang J, Zhang N, Wang S, Liang W, Zhao H, Xia W, et al. AI approach to biventricular function assessment in cine-MRI: an ultra-small training dataset and multivendor study. *Phys Med Biol*. 2023;68(24):245025. doi: [10.1088/1361-6560/ad0903](https://doi.org/10.1088/1361-6560/ad0903)
22. Gautam A, Raghav P, Subramanya V, Kumar S, Kumar S, Jain D, et al. Fully Automated Agatston score calculation from ECG gated Cardiac CT using Deep learning and Multiorgan Segmentation: A Validation study. *Research Square*. 2022. doi: [10.21203/rs.3.rs-2347144/v1](https://doi.org/10.21203/rs.3.rs-2347144/v1)
23. Tian D, Yu N, Mao T, Li Y, Liu R, Xu Y, et al. Prediction of long-term major adverse cardiac events after myocardial infarction: value of combination of inflammatory biomarkers and GRACE score. *Front Cardiovasc Med*. 2025;12(1591578):1591578. doi: [10.3389/fcvm.2025.1591578](https://doi.org/10.3389/fcvm.2025.1591578)
24. Shinohara H, Kodera S, Nagae Y, Hiruma T, Kobayashi A, Sato M, et al. The potential of the transformer-based survival analysis model, SurvTrace, for predicting recurrent cardiovascular events and stratifying high-risk patients with ischemic heart disease. *PLoS One*. 2024;19(6):e0304423. doi: [10.1371/journal.pone.0304423](https://doi.org/10.1371/journal.pone.0304423)
25. Moltó-Balado P, Reverté-Villarroya S, Alonso-Barberán V, Monclús-Arasa C, Balado-Albiol MT, Clua-Queralt J, et al. Machine learning approaches to predict Major Adverse Cardiovascular Events in atrial fibrillation. *Technologies (Basel)*. 2024;12(2):13. doi: [10.3390/technologies12020013](https://doi.org/10.3390/technologies12020013)
26. Oo MM, Gao C, Cole C, Hummel Y, Guignard-Duff M, Jefferson E, et al. Artificial intelligence-assisted automated heart failure detection and classification from electronic health records. *ESC Heart Fail*. 2024;11(5):2769–77. doi: [10.1002/ehf2.14828](https://doi.org/10.1002/ehf2.14828)
27. Shao Y, Zhang S, Raman VK, Patel SS, Cheng Y, Parulkar A, et al. Artificial intelligence approaches for phenotyping heart failure in U.S. Veterans Health Administration electronic health record. *ESC Heart Fail*. 2024;11(5):3155–66. doi: [10.1002/ehf2.14787](https://doi.org/10.1002/ehf2.14787)
28. Mortazavi BJ, Downing NS, Bucholz EM, Dharmarajan K, Manhapra A, Li SX, et al. Analysis of machine learning techniques for heart failure readmissions. *Circ Cardiovasc Qual Outcomes*. 2016;9(6):629–40. doi: [10.1161/circoutcomes.116.003039](https://doi.org/10.1161/circoutcomes.116.003039)
29. Banerjee A, Chen S, Fatemifar G, Zeina M, Lumbers RT, Mielke J, et al. Machine learning for subtype definition and risk prediction in heart failure, acute coronary syndromes and atrial fibrillation: systematic review of validity and clinical utility. *BMC Med*. 2021;19(1):85. doi: [10.1186/s12916-02101940-7](https://doi.org/10.1186/s12916-02101940-7)
30. Weller J, Gutton J, Hocquet G, Pellet L, Aroulanda MJ, Bruandet A, et al. Prediction of 90 day mortality in elderly patients with acute HF from e-health records

- using artificial intelligence. *ESC Heart Fail.* 2025;12(3):2200–9. doi: [10.1002/ehf2.15244](https://doi.org/10.1002/ehf2.15244)
31. Kwon JM, Kim KH, Jeon KH, Lee SE, Lee HY, Cho HJ, et al. Artificial intelligence algorithm for predicting mortality of patients with acute heart failure. *PLoS One.* 2019;14(7):e0219302. doi: [10.1371/journal.pone.0219302](https://doi.org/10.1371/journal.pone.0219302)
 32. Kasem Ali Sliman R, Eitan A, Zisman K, Avidan Y, Aker A, Sliman H. Three-cusp view orientation in TAVI: Evaluating LOA versus non-LOA impact on outcomes with contemporary valve prostheses. *Catheter Cardiovasc Interv.* 2025;106(4):2567–78. doi: [10.1002/ccd.70087](https://doi.org/10.1002/ccd.70087)
 33. Butter C, Kaneko H, Tambor G, Hara M, Neuss M, Hoelschermann F. Clinical utility of intraprocedural three-dimensional integrated image guided transcatheter aortic valve implantation using novel automated computed tomography software: A single-center preliminary experience. *Catheter Cardiovasc Interv.* 2019;93(4):722–8. doi: [10.1002/ccd.27920](https://doi.org/10.1002/ccd.27920)
 34. Felbel D, Buck C, Riedel N, Paukovitsch M, Stephan T, Krohn-Grimberghe M, et al. Combined computed coronary tomography angiography and transcatheter aortic valve implantation (TAVI) planning computed tomography reliably detects relevant coronary artery disease pre-TAVI. *J Clin Med.* 2024;13(16):4885. doi: [10.3390/jcm13164885](https://doi.org/10.3390/jcm13164885)
 35. Panuccio G, Abdelwahed YS, Carabetta N, Salerno N, Leistner DM, Landmesser U, et al. Clinical and procedural outcomes of IVUS-guided vs. Angiography-guided CTO-PCI: A systematic review and meta-analysis. *J Clin Med.* 2023;12(15):4947. doi: [10.3390/jcm12154947](https://doi.org/10.3390/jcm12154947)
 36. Hoque A, Ahmed I, Nahar N, Saria SJ, Islam S, MD Mehedi Hasan, et al. Ai-assisted imaging and navigation in Minimally invasive cardiac interventions - a systematic review. *Insights-Journal of Health and Rehabilitation.* 2025;3(2):538–44. doi: [10.71000/ky41as49](https://doi.org/10.71000/ky41as49)
 37. Hopkisson O, Ibrahim A, Swinn T, Dastidar A, Satti Z. Contemporary review of cardiovascular computed tomography in coronary and structural heart interventions. *Preprints.* 2025. doi: [10.20944/preprints202502.1726.v1](https://doi.org/10.20944/preprints202502.1726.v1)
 38. Ashiq K, Ashiq S, Mustafa N. Pharmacogenomics and the concept of personalized medicine for the management of hypertension. *Pak Hear J.* 2023;56(2):188–90. doi: [10.47144/phj.v56i2.2553](https://doi.org/10.47144/phj.v56i2.2553)
 39. Afrose N, Chakraborty R, Hazra A, Bhowmick P, Bhowmick M. AI-driven drug discovery and development. In: *Future of AI in Biomedicine and Biotechnology.* IGI Global; 2024. p. 259–77. doi: [10.4018/979-8-3693-3629-8.ch013](https://doi.org/10.4018/979-8-3693-3629-8.ch013)
 40. Iftikhar H. AI-driven pharmacovigilance and molecular profiling of fluoroquinolone-associated cardiotoxicity in the UAE: A geospatial and machine learning analysis with structural modification strategies (2018–2023). *medRxiv.* 2025. doi: [10.1101/2025.05.10.25327319](https://doi.org/10.1101/2025.05.10.25327319)
 41. Szymańska K, Szmyt K, Krasnoborska J, Samojedny S, Superson M, Walczak K, et al. Revolutionizing cardiovascular treatments with the use of AI: Current status and future prospects. *Qual Sport.* 2024;19:53072. doi: [10.12775/qs.2024.19.53072](https://doi.org/10.12775/qs.2024.19.53072)
 42. Chandan TR, Patil CD, Kundgir VB, Chaudhari K, Bachhav RL, Bhamare MS, et al. Pharmacogenomics and personalized medicine: A revolution in drug therapy. *Res J Pharmacol Pharmacodyn.* 2025;311–8. doi: [10.52711/2321-5836.2025.00048](https://doi.org/10.52711/2321-5836.2025.00048)
 43. Kawamoto K, Houlihan CA, Balas EA, Lobach DF. Improving clinical practice using clinical decision support systems: a systematic review of trials to identify features critical to success. *BMJ.* 2005;330(7494):765. doi: [10.1136/bmj.38398.500764.8f](https://doi.org/10.1136/bmj.38398.500764.8f)
 44. Cai J, Li P, Li W, Zhu T. Outcomes of clinical decision support systems in real-world perioperative care: a systematic review and meta-analysis. *Int J Surg.* 2024;110(12):8057–72. doi: [10.1097/js9.0000000000001821](https://doi.org/10.1097/js9.0000000000001821)
 45. Bozyel S, Şimşek E, Koçyiğit Burunkaya D, Güler A, Korkmaz Y, Şeker M, et al. Artificial intelligence-based clinical decision support systems in cardiovascular diseases. *Anatol J Cardiol.* 2024;74–86. doi: [10.14744/anatoljcardiol.2023.3685](https://doi.org/10.14744/anatoljcardiol.2023.3685)
 46. Giuste F, Shi W, Zhu Y, Naren T, Isgut M, Sha Y, et al. Explainable Artificial Intelligence methods in combating pandemics: A systematic review. *IEEE Rev Biomed Eng.* 2023;16:5–21. doi: [10.1109/rbme.2022.3185953](https://doi.org/10.1109/rbme.2022.3185953)
 47. Linardatos P, Papastefanopoulos V, Kotsiantis S. Explainable AI: A review of machine learning interpretability methods. *Entropy (Basel).* 2020;23(1):18. doi: [10.3390/e23010018](https://doi.org/10.3390/e23010018)
 48. Aasem M, Javed Iqbal M. Toward explainable AI in radiology: Ensemble-CAM for effective thoracic disease localization in chest X-ray images using weak supervised learning. *Front Big Data.* 2024;7:1366415. doi: [10.3389/fdata.2024.1366415](https://doi.org/10.3389/fdata.2024.1366415)
 49. Petch J, Di S, Nelson W. Opening the black box: The promise and limitations of explainable machine learning in cardiology. *Can J Cardiol.* 2022;38(2):204–13. doi: [10.1016/j.cjca.2021.09.004](https://doi.org/10.1016/j.cjca.2021.09.004)
 50. Jones RK. Algorithmic bias and fairness in biomedical and health research. In: *Advances in Computational Intelligence and Robotics.* IGI Global Scientific Publishing; 2025. p. 287–324. doi: [10.4018/9798-3373-4252-8.ch008](https://doi.org/10.4018/9798-3373-4252-8.ch008)
 51. Oyeniran OC, Adewusi AO, Adeleke AG, Akwawa LA, Azubuko CF. Ethical AI: Addressing bias in machine learning models and software applications. *Comput sci IT res j.* 2022;3(3):115–26. doi: [10.51594/csitrj.v3i3.1559](https://doi.org/10.51594/csitrj.v3i3.1559)

52. Bhimavarapu U. Bias in AI-driven diabetes prediction models: Challenges, impacts, and mitigation strategies. In: *Advances in Computational Intelligence and Robotics*. IGI Global; 2025. p. 195–214. doi: [10.4018/979-8-3693-9735-0.ch008](https://doi.org/10.4018/979-8-3693-9735-0.ch008)
53. Saleiro P, Kuester B, Hinkson L, London J, Stevens A, Anisfeld A, et al. Aequitas: A bias and fairness audit toolkit. arXiv. 2018. doi: [10.48550/arxiv.1811.05577](https://doi.org/10.48550/arxiv.1811.05577)
54. Dakshit S, Dakshit S, Khargonkar N, Prabhakaran B. Bias analysis in healthcare time series (BAHT) decision support systems from meta data. *J Healthc Inform Res*. 2023;7(2):225–53. doi: [10.1007/s41666023-00133-6](https://doi.org/10.1007/s41666023-00133-6)
55. Al-Nafjan A, Aljuhani A, Alshebel A, Alharbi A, Alshehri A. Artificial intelligence in predictive healthcare: A systematic review. *J Clin Med*. 2025;14(19):6752. doi: [10.3390/jcm14196752](https://doi.org/10.3390/jcm14196752)