

Artículo de revisión

Inteligencia artificial y enfoques diagnósticos multimodales en enfermedad cardiovascular

Fernando A. Ramos-Zaga ^{1,a}Recibido: 16 de agosto de 2025
Aceptado: 19 de noviembre de 2025
En línea: 30 de noviembre de 2025

Filiación de los autores

¹ Universidad Privada del Norte,
Lima, Perú.^a Doctor en Salud Pública.

Correspondencia

Av. Nicolás Ayllón 8510, Ate, Lima-
Perú.

Correo

fernandozaga@gmail.com

Fuente de financiamiento

Autofinanciado.

Conflictos de interés

Ninguno.

Citar como

Ramos-Zaga FA. Inteligencia artificial
y enfoques diagnósticos multimodales en enfermedad cardiovascular.
Arch Peru Cardiol Cir Cardiovasc.
2025;6(4):230-238. doi: 10.47487/ap-
cyccv.v6i4.532.Esta obra tiene una licencia de
Creative Commons Atribución
4.0 Internacional

RESUMEN

Objetivo. Evaluar el impacto y la aplicabilidad clínica de los modelos de inteligencia artificial (IA) en el diagnóstico cardiovascular, analizando su capacidad para mejorar la precisión, la eficiencia operativa y la confiabilidad en comparación con métodos convencionales. **Materiales y métodos.** Se realizó una revisión crítica de la literatura reciente, incluyendo estudios retrospectivos, multicéntricos y validaciones externas que aplicaron algoritmos de *machine learning* y *deep learning* a modalidades de imagen, señales electrocardiográficas y fonocardiográficas, así como biomarcadores clínicos y proteómicos. **Resultados.** Los hallazgos muestran que en imágenes cardíacas, la segmentación automática y la detección de disfunción ventricular alcanzan métricas de precisión superiores al 90%, con potencial de integración clínica. En señales cardíacas, el *deep learning* ha demostrado áreas bajo la curva ROC cercanas a 0,99 en la predicción de fibrilación auricular y cardiopatía isquémica, reforzadas por técnicas explicables. En biomarcadores, los modelos de *ensemble* superaron el 95% de precisión diagnóstica y la integración de proteómica con datos clínicos incrementó la capacidad predictiva. Sin embargo, se observó una disminución en el desempeño de validaciones externas, limitaciones en la generalización a poblaciones heterogéneas y reticencia por la escasa explicabilidad de algunos algoritmos. **Conclusión.** La IA aplicada al diagnóstico cardiovascular exhibe un potencial transformador al mejorar la precisión diagnóstica, reducir la variabilidad y ampliar el acceso a entornos con recursos limitados. No obstante, su consolidación en la práctica clínica requiere validaciones multicéntricas, interoperabilidad con flujos clínicos reales y fortalecimiento de la explicabilidad, condiciones esenciales para su inclusión en guías de práctica clínica y medicina de precisión.

Palabras clave: Inteligencia Artificial; Aprendizaje Automático; Técnicas de Diagnóstico Cardiovascular; Medicina de Precisión (Fuente: DeCS-BIREME).

ABSTRACT

Artificial intelligence and multimodal diagnostic approaches in cardiovascular disease

Objective. Evaluate the impact and clinical applicability of artificial intelligence (AI) models in cardiovascular diagnosis, assessing their potential to improve diagnostic accuracy, operational efficiency, and reliability compared with conventional methods. **Materials and Methods.** A critical review of the recent literature was conducted, encompassing retrospective studies, multicenter trials, and external validations that employed machine learning and deep learning algorithms applied to imaging modalities, electrocardiographic and phonocardiographic signals, as well as clinical and proteomic biomarkers. **Results.** Evidence indicates that in cardiac imaging, automated segmentation and ventricular dysfunction detection achieved accuracy metrics exceeding 90%, suggesting readiness for clinical integration. In cardiac signals, deep learning models demonstrated area under the ROC curve values of approximately 0.99 for predicting atrial fibrillation and ischemic heart disease, further supported by explainability techniques. Regarding biomarkers, ensemble models achieved diagnostic accuracies above 95%, and the integration of proteomic and clinical data substantially enhanced predictive performance. Nonetheless, decreased performance in external validations, limited generalizability to heterogeneous populations, and clinicians' reluctance due to insufficient explainability remain major barriers. **Conclusion.** Artificial intelligence in cardiovascular diagnostics holds transformative potential by improving accuracy, reducing interobserver variability, and expanding access in resource-limited settings. However, its consolidation into routine practice requires robust multicenter validations, seamless interoperability with clinical workflows, and strengthened explainability, prerequisites for incorporation into clinical guidelines and precision medicine strategies.

Keywords: Artificial Intelligence; Machine Learning; Diagnostic Techniques, Cardiovascular; Precision Medicine (Source: MeSH-NLM).

Introducción

El diagnóstico cardiovascular se encuentra en un periodo de transición marcado por la incorporación de herramientas de inteligencia artificial (IA) en distintos niveles de la práctica clínica. La convergencia entre avances en modalidades de imagen, análisis de señales cardíacas y biomarcadores ha abierto oportunidades inéditas para mejorar la precisión, la eficiencia y la escalabilidad de los diagnósticos⁽¹⁾. Sin embargo, este proceso no ocurre en un vacío: está condicionado por la creciente prevalencia global de enfermedades cardiovasculares y por la necesidad de optimizar recursos en sistemas de salud que enfrentan presiones crecientes.

El interés por aplicar algoritmos al campo médico tiene una trayectoria que se remonta a los sistemas expertos iniciales⁽²⁾, evolucionando hacia el aprendizaje automático y, más recientemente, hacia el *deep learning* aplicado a imágenes y señales fisiológicas⁽³⁾. En cardiología, estos enfoques han permitido logros notables en la detección automática de disfunción ventricular⁽⁴⁾, en la predicción de fibrilación auricular a partir de electrocardiogramas en ritmo sinusal⁽⁵⁾ y en la integración de biomarcadores proteómicos con datos clínicos a gran escala⁽⁶⁾.

No obstante, se observa una brecha persistente entre la eficacia técnica de los modelos y su maduración clínica. A pesar de métricas sobresalientes en entornos controlados, estudios multicéntricos han demostrado caídas sustanciales en el rendimiento cuando los algoritmos se enfrentan a poblaciones heterogéneas y a condiciones de calidad variable de las imágenes o señales⁽⁷⁾. Este problema, señalado en la literatura de ciencias de la computación como un desafío de generalización⁽⁸⁾, se manifiesta de manera crítica en cardiología, donde la diversidad de fenotipos y comorbilidades exige robustez y flexibilidad metodológica.

La justificación de profundizar en este campo radica en que los actuales avances no han logrado consolidarse como prácticas rutinarias. La existencia de métricas sobresalientes en estudios retrospectivos contrasta con la limitada disponibilidad de validaciones longitudinales, externas y multicéntricas que aseguren su utilidad clínica⁽⁹⁾. Además, la ausencia de explicabilidad suficiente refuerza la reticencia de los clínicos a adoptar algoritmos de «caja negra», dificultando su incorporación en la toma de decisiones.

Las implicaciones prácticas de este proceso son notables. Una IA capaz de interpretar imágenes, electrocardiogramas y biomarcadores de manera robusta podría no solo optimizar diagnósticos en entornos especializados, sino también ampliar el acceso en contextos con recursos limitados mediante dispositivos portátiles y análisis automatizados⁽¹⁰⁾. Del mismo modo, la integración de información multimodal permitiría abordar la complejidad clínica desde una perspectiva más holística, superando las limitaciones de los enfoques unimodales⁽¹¹⁾.

Lo antes planteado se conecta con desafíos contemporáneos más amplios en medicina, como la necesidad de desarrollar modelos éticos y transparentes, evitar sesgos algorítmicos y garantizar que las innovaciones tecnológicas no profundicen

desigualdades estructurales⁽¹²⁾. Además, se alinea con las prioridades de la medicina de precisión, que busca integrar datos moleculares, clínicos y poblacionales para individualizar el cuidado⁽¹³⁾. Así, el debate sobre la madurez de la IA en cardiología trasciende lo puramente técnico para situarse en un plano de relevancia social, ética y económica.

En este marco, el objetivo de este trabajo es analizar críticamente los avances recientes en el diagnóstico cardiovascular asistido por inteligencia artificial, considerando modalidades de imagen, señales cardíacas y biomarcadores, con el fin de establecer un marco de referencia que permita valorar su grado de madurez, precisión y aplicabilidad clínica en distintos escenarios. La contribución de este artículo radica en ofrecer una síntesis que identifique tanto las oportunidades como las limitaciones actuales, abriendo el camino hacia una integración más sólida, explicable y equitativa de la IA en la práctica clínica cardiovascular.

Materiales y métodos

El presente artículo adopta el formato de revisión narrativa crítica según el marco SANRA (*Scale for the Assessment of Narrative Review Articles*), dado que el objetivo principal es integrar y analizar de manera interpretativa la evidencia reciente sobre IA en diagnóstico cardiovascular, considerando su aplicabilidad clínica y su grado de madurez tecnológica. Este enfoque permite contextualizar los hallazgos en un marco teórico y clínico amplio, superando la mera agregación de resultados cuantitativos y proporcionando una comprensión conceptual del fenómeno.

El propósito metodológico fue identificar, examinar y discutir críticamente los avances recientes en el uso de IA para el diagnóstico cardiovascular mediante imágenes, señales y biomarcadores. La revisión busca evaluar la robustez, explicabilidad y aplicabilidad clínica de los modelos, destacando tanto sus logros como sus limitaciones en la práctica médica.

Se incluyeron estudios originales (prospectivos, retrospectivos, multicéntricos o clínicos) que cumplieran las siguientes condiciones: a) Aplicar modelos de inteligencia artificial al diagnóstico cardiovascular por imagen, señal o biomarcadores; b) Reportar métricas cuantitativas de desempeño (área bajo la curva [AUC], sensibilidad, especificidad, F1-score u otras); c) Contar con validación interna o externa.

Se excluyeron revisiones narrativas, editoriales, resúmenes de congreso, estudios conceptuales sin datos empíricos y artículos sin reporte de métricas diagnósticas o sin aplicación clínica validada.

La búsqueda bibliográfica se efectuó entre enero y agosto de 2025. Se aplicaron combinaciones de términos controlados y no controlados, empleando operadores booleanos: ("artificial intelligence" OR "machine learning" OR "deep learning") AND ("cardiovascular diagnosis" OR "cardiac imaging" OR "electrocardiogram" OR "biomarkers"). Se incluyeron artículos publicados entre 2018 y 2025 en inglés o español, a fin de abarcar la literatura contemporánea de mayor impacto.

La búsqueda inicial en las bases de datos Scopus, PubMed e IEEE Xplore identificó un total de 152 registros, distribuidos

de la siguiente forma: IEEE Xplore (66), Scopus (49) y PubMed (37). Esta amplitud refleja el crecimiento de las investigaciones sobre IA aplicada al diagnóstico cardiovascular, que abarca desde modelos de imagen médica hasta algoritmos predictivos basados en señales y biomarcadores. La presencia de numerosos registros redundantes y de publicaciones con baja pertinencia temática coincide con lo observado en otros campos emergentes de la medicina computacional.

La eliminación automática de duplicados mediante el *software* Zotero permitió excluir 24 registros, dejando 128 artículos únicos para la fase inicial de cribado. Este proceso redujo posibles sesgos por repetición bibliográfica y garantizó la unicidad de cada referencia analizada. Durante el cribado de títulos y resúmenes, se excluyeron 26 registros que no cumplían con los criterios de elegibilidad. Las razones principales fueron la ausencia de aplicación directa al diagnóstico cardiovascular, la orientación puramente técnica sin validación clínica o la falta de coherencia con el objetivo del estudio.

Posteriormente, se intentó recuperar el texto completo de 102 estudios, de los cuales cinco no pudieron obtenerse por restricciones de acceso o disponibilidad editorial. Los 97 artículos restantes fueron sometidos a evaluación de elegibilidad, aplicando criterios previamente definidos relativos a calidad metodológica, pertinencia diagnóstica y reporte de métricas de desempeño. En esta fase, 59 registros fueron excluidos, ya sea por carencia de datos empíricos ($n = 23$), información incompleta ($n = 28$) o deficiente calidad metodológica ($n = 8$). Finalmente, 38 estudios cumplieron todos los criterios de inclusión (**Figura 1**).

Los resultados de búsqueda se depuraron mediante un proceso de revisión. Se utilizó un formulario estandarizado para la extracción de datos que incluyó: tipo de modelo de IA, modalidad diagnóstica, tamaño muestral, diseño del estudio, métrica de desempeño y validación. Los registros bibliográficos fueron organizados y verificados mediante el *software* Zotero, garantizando trazabilidad y control de duplicados.

La información se estructuró según las tres dimensiones diagnósticas principales: imagen cardiovascular, señales




Figura 1. Identificación de estudios a través de bases de datos y registros.

cardíacas y biomarcadores. Se empleó un análisis crítico cualitativo, identificando patrones de desempeño, consistencia metodológica y grado de madurez clínica. La síntesis buscó integrar la evidencia con un enfoque interpretativo, valorando la explicabilidad, la interoperabilidad y la generalización de los modelos, más allá de sus métricas técnicas.

Resultados

Diagnóstico por imagen

Los avances en diagnóstico por imagen cardiovascular han transformado de manera progresiva la precisión y la eficiencia en la evaluación clínica, particularmente en ecocardiografía, resonancia magnética, tomografía computarizada y enfoques multimodales. En ecocardiografía, los progresos en la segmentación automática de cavidades y válvulas han permitido superar las métricas clásicas de desempeño, mostrando una robustez notable frente a la variabilidad anatómica y la calidad de las imágenes. Un modelo basado en U-Net con módulos ASPP alcanzó un F1-score de 0,91 y un coeficiente Dice de 0,9284, lo que sugiere que estas herramientas están listas para una eventual integración clínica ⁽¹⁴⁾. En un análisis de 15 000 estudios, la segmentación automática del ventrículo izquierdo permitió calcular la fracción de eyección (FEy) con alta precisión y con una tasa de acierto del 93% en la identificación de vistas, aunque con limitaciones en la fibrilación auricular y en la baja calidad de imagen ⁽¹⁵⁾.

De forma complementaria, un modelo adversarial alcanzó coeficientes Dice superiores al 86% en múltiples cavidades, con una correlación de volúmenes de 0,94 respecto a la segmentación manual ⁽¹⁶⁾. Otros enfoques, como las redes con atención trilateral, han demostrado capacidad para segmentar y cuantificar en tiempo real, superando a expertos en cuatro bases de datos independientes ⁽¹⁷⁾. Asimismo, la implementación de sistemas de control de calidad aumentó la proporción de *frames* utilizables hasta el 96%, reforzando la aplicabilidad en la práctica clínica ⁽¹⁸⁾.

La detección automática de disfunción ventricular también ha alcanzado logros notables. Un estudio multicéntrico con más de 147 000 pacientes demostró un AUC (área bajo la curva) de 0,94 para FEy reducida y de 0,84 para disfunción del ventrículo derecho, con bajo error absoluto frente a la referencia ⁽¹⁹⁾. Otro análisis de más de 200 000 individuos mostró que el electrocardiograma (ECG) puede predecir presión de llenado y grados de disfunción diastólica izquierda con AUC superiores a 0,91, equiparables al rendimiento de la ecocardiografía ⁽²⁰⁾. En un escenario más accesible, la combinación de fonocardiograma y ECG a través de parches portátiles alcanzó un AUROC (área bajo la curva característica del receptor) de hasta 0,91, con sensibilidades superiores al 90%, lo que refuerza su utilidad en entornos con recursos limitados ⁽²¹⁾. La integración multimodal de auscultación y ECG demostró un beneficio adicional, con AUC de 0,75 en cohortes internas y externas, confirmando que la combinación de sensores puede optimizar la detección de disfunción ventricular ⁽²²⁾.

La resonancia magnética (RM) y la tomografía computarizada han ofrecido nuevas perspectivas en la detección y cuantificación de enfermedad cardiovascular. En el contexto de

cardiopatía isquémica, el uso de redes profundas optimizadas con Levenberg-Marquardt permitió alcanzar una precisión del 86,39% y un AUC de 0,93 en la detección de isquemia miocárdica, con adecuada correlación en volúmenes ventriculares ⁽²³⁾. De manera complementaria, la angiotomografía coronaria asistida por inteligencia artificial mostró una sensibilidad del 75% y una especificidad del 70% frente a la angiografía invasiva, con un valor predictivo negativo particularmente alto en mujeres, superando el rendimiento de SPECT (tomografía computarizada por emisión de fotón único) ⁽²⁴⁾. En cuanto a la cuantificación de fibrosis y viabilidad, un algoritmo en tomografía nativa logró una correlación significativa con realce tardío de RM ($r = 0,77-0,81$), con reproducibilidad casi perfecta, aunque validado en una cohorte reducida ⁽²⁵⁾. Paralelamente, el análisis de cine-RM alcanzó precisiones del 89% en validación, pero con una caída al 70% en pruebas externas, reflejando la necesidad de optimización ⁽²⁶⁾. Otros métodos, como las máquinas de soporte vectorial aplicadas a RM poscontraste, alcanzaron precisiones del 71% y sensibilidades del 72%, en algunos casos superando a redes profundas ⁽²⁷⁾. El análisis de textura en ecocardiografía aportó concordancias de hasta el 76% frente a RM, con mejores resultados en cicatrices transmural y tras el uso de contraste, lo que abre posibilidades en escenarios posinfarto ⁽²⁸⁾.

La integración de modalidades de imagen y otras fuentes de información ha emergido como un enfoque particularmente prometedor. La fusión de la angiotomografía coronaria (TC) y RM mediante un modelo XGBoost alcanzó un AUC de 0,86, con validaciones externas que reportaron hasta 0,92, superando a los scores clínicos tradicionales de riesgo cardiovascular ⁽¹¹⁾. El empleo de redes DenseResNet aplicadas a la combinación de RM, TC y ecocardiografía reportó una precisión del 98,4%, con sensibilidades y especificidades también superiores al 97%, mostrando clara ventaja frente a modelos unimodales ⁽²⁹⁾. En un enfoque más modesto, la fusión tardía de ECG y registros clínicos permitió alcanzar una precisión del 72,2%, aunque con limitaciones relacionadas con el tamaño de la muestra ⁽³⁰⁾. Finalmente, la integración de ecocardiograma, ECG y parámetros bioquímicos alcanzó una precisión del 89,87%, con un *recall* del 91,20% y un F1-score del 89,13%, resultados validados en cohortes clínicas que respaldan la aplicabilidad real de este tipo de algoritmos multimodales ⁽³¹⁾ (**Tabla 1**).

Diagnóstico por señales

Los avances en el análisis de señales cardíacas han abierto un panorama cada vez más amplio para el diagnóstico no invasivo de diversas condiciones cardiovasculares. En el campo del ECG, los modelos de IA han demostrado una capacidad notable para la detección temprana de fibrilación auricular (FA). Un estudio retrospectivo que incluyó más de 135 000 registros mostró que tanto los algoritmos clásicos como las redes profundas alcanzaron sensibilidades del 90%, aunque la especificidad fue superior con *deep learning*, situándose en 69% frente al 62% de los modelos convencionales, siempre en comparación con el diagnóstico de un cardiólogo como referencia ⁽³²⁾.

El desarrollo de modelos predictivos ha ampliado aun más el alcance de estas tecnologías. En una cohorte de más de 318 000 pacientes y más de medio millón de ECG, un modelo de *deep*

Tabla 1. Modelos de IA aplicados al diagnóstico por imagen cardiovascular

Grupo de estudios	Modelos predominantes	Modalidad / tipo de datos	Aprendizaje	Estrategia de validación
Segmentación y cuantificación ecocardiográfica ^(14–18)	CNN (U-Net, variantes con atención y GAN)	Imágenes 2D de ecocardiografía	Supervisado y semisupervisado	Validación cruzada y externa en múltiples bases
Detección de disfunción ventricular y predicción funcional ^(19–22)	CNN profundas y modelos multimodales (ECG + fonocardiograma)	Imágenes 2D y señales 1D	Supervisado	Validaciones multicéntricas y externas
Diagnóstico estructural por RM y TC ^(23–28)	CNN, SVM y algoritmos <i>ensemble</i>	Imágenes 2D y 3D	Supervisado	Validación interna y externa
Integración multimodal ^(11, 29–31)	DenseResNet, XGBoost y <i>ensemble</i>	Combinación de RM, TC, ecocardiografía, ECG y biomarcadores	Supervisado	Validaciones externas y clínicas

CNN: redes neuronales convolucionales. SVM: máquina de soporte vectorial. RM: resonancia magnética. TC: tomografía cardíaca. ECG: electrocardiograma

learning entrenado para predecir FA paroxística en sujetos con ritmo sinusal normal alcanzó un AUROC de $0,905 \pm 0,007$ en la predicción a un mes, incorporando, además, técnicas explicables que permitieron interpretar la contribución de los distintos segmentos del trazado ⁽³³⁾.

Otros enfoques se han centrado en integrar parámetros clásicos del ECG, como la morfología de la onda P y la variabilidad de la frecuencia cardíaca. Con esta aproximación, un modelo de *ensemble learning* logró una precisión del 92%, sensibilidad del 88% y especificidad del 96%, con un AUROC de 0,911 en bases públicas, demostrando que el *stacking* puede superar a otros métodos combinatorios ⁽³⁴⁾. En una línea diferente, el entrenamiento de redes neuronales convolucionales con decenas de miles de segmentos de *Holter* alcanzó sensibilidades

del 97,1% y especificidades del 94,5%, con un AUROC cercano a 0,99. El uso de Grad-CAM permitió validar la coherencia clínica de las regiones señaladas por el modelo, lo que refuerza la robustez de este enfoque en la práctica real ⁽³⁵⁾.

La aplicación del ECG a la detección de cardiopatía isquémica ha mostrado resultados consistentes en distintos escenarios. En una de las bases más utilizadas para este propósito, un modelo SVM (*support vector machine*) alcanzó una precisión del 97,98% en la clasificación de fragmentos isquémicos, lo que demuestra su utilidad para el análisis a gran escala, si bien aún requiere validación en cohortes clínicas ⁽³⁶⁾. En un estudio que combinó ECG y VCG (vectocardiograma), la precisión alcanzó el 90,3%, con sensibilidades y especificidades equivalentes, y un AUC de 0,814 en cohortes externas, confirmando una adecuada capacidad de

Tabla 2. Modelos de IA aplicados al diagnóstico por señales cardíacas

Grupo de estudios	Modelos predominantes	Modalidad / tipo de datos	Aprendizaje	Estrategia de validación
Detección y predicción de fibrilación auricular ^(32–35)	CNN, redes recurrentes (RNN/LSTM) y <i>ensemble learning</i>	ECG y registros Holter (señales 1D)	Supervisado y parcialmente explicable	Validaciones internas y externas, algunas multicéntricas
Diagnóstico de cardiopatía isquémica ^(36–38)	SVM, CNN y modelos híbridos ECG–VCG	ECG y vectocardiografía	Supervisado	Validaciones cruzadas y multicéntricas frente a angiografía coronaria
Identificación de valvulopatías mediante fonocardiograma ^(39–42)	CNN, Vision Transformer y modelos autosupervisados	Fonocardiogramas digitales	Supervisado y autosupervisado	Validación prospectiva y en práctica real
Análisis avanzado de soplos y clasificación jerárquica ^(43–45)	CNN con transferencia, modelos multitarea y SHAP	Mel-espectrogramas y fonocardiogramas	Supervisado con interpretabilidad	Validaciones internas y externas con ecocardiografía como referencia

CNN: redes neuronales convolucionales. RNN: red neuronal recurrente. LSTM: memoria a corto plazo y largo. SVM: máquina de soporte vectorial. ECG: electrocardiograma. VCG: vectocardiograma.

generalización⁽³⁷⁾. La validación multicéntrica en 595 pacientes reforzó la aplicabilidad de la vectocardiografía asistida por *machine learning*, alcanzando sensibilidades superiores al 97% en hombres y al 90% en mujeres, con una validación cruzada consistente frente a la angiografía coronaria⁽³⁸⁾.

El análisis de fonocardiogramas ha mostrado progresos igualmente relevantes en la identificación de valvulopatías. En un estudio multicéntrico con casi quinientos pacientes, las sensibilidades oscilaron entre 71,4% y 100% y las especificidades entre 83,5% y 100%, con desempeño óptimo en estenosis mitral, donde se alcanzó el 100% en todos los parámetros, validado de manera prospectiva frente a ecocardiografía⁽³⁹⁾. La introducción de señales obtenidas con dispositivos móviles y técnicas de aprendizaje autosupervisado elevó la precisión por encima del 99,4%, incluso en condiciones con ruido, lo que abre la puerta al cribado masivo en entornos de salud móvil⁽⁴⁰⁾. Al comparar arquitecturas, los modelos basados en *Vision Transformer* lograron una precisión del 99,90% y un F1-score del 99,95%, superando a enfoques más tradicionales y mostrando la ventaja de los mecanismos de atención⁽⁴¹⁾. En un escenario de práctica real, un estetoscopio digital con IA logró una sensibilidad del 94,1%, notablemente superior al 41,2% alcanzado por médicos de atención primaria, aunque con una menor especificidad, lo que refuerza su papel en la detección temprana y en la derivación selectiva⁽⁴²⁾.

El análisis de soplos cardíacos con correlación directa a ecocardiografía ha demostrado utilidad tanto en población pediátrica como en adultos. En una cohorte prospectiva de 116 niños, los modelos clásicos alcanzaron precisiones superiores al 90% para diferenciar soplos orgánicos relacionados con cardiopatías congénitas, con validación directa frente a ecocardiografía⁽⁴³⁾. En un plano más avanzado, el uso de modelos jerárquicos multitarea, entrenados con bases públicas, permitió no solo detectar y graduar soplos, sino también realizar estimaciones de riesgo, con interpretabilidad lograda a través de técnicas como SHAP (explicaciones aditivas de Shapley), lo que los convierte en una herramienta potencialmente útil para optimizar derivaciones⁽⁴⁴⁾. Finalmente, la implementación de mel-espectrogramas procesados mediante redes de transferencia

alcanzó clasificaciones rápidas y robustas de presencia y severidad de soplos, con explicabilidad basada en *Occlusion Sensitivity*, lo que demuestra su valor como método de cribado complementario a la ecocardiografía⁽⁴⁵⁾ (**Tabla 2**).

Diagnóstico por biomarcadores

El estudio de biomarcadores en el diagnóstico cardiovascular ha evolucionado hacia la integración de métodos de aprendizaje automático capaces de manejar grandes volúmenes de datos clínicos y de laboratorio. En un análisis comparativo que incluyó ocho algoritmos clásicos y de *ensemble*, el preprocesamiento exhaustivo con normalización, balanceo y selección de variables permitió alcanzar precisiones superiores al 98%, lo que confirma el valor de combinar múltiples técnicas en cohortes amplias y heterogéneas⁽⁴⁶⁾.

En una cohorte más reducida de 224 pacientes, la evaluación de seis algoritmos distintos mostró la viabilidad del aprendizaje automático para diagnóstico preventivo utilizando datos de laboratorio. A pesar de no presentar métricas numéricas detalladas, los hallazgos sugieren que esta aproximación puede ser útil, aunque la falta de validaciones extensas limita su estandarización en la práctica clínica⁽⁴⁷⁾.

El potencial de los modelos *ensemble* también se observó en un análisis de 100 pacientes, donde se aplicaron cinco algoritmos a variables clínicas básicas como edad, presión arterial y colesterol. *Gradient Boosting* alcanzó una precisión máxima de 92,5%, superando a *Random Forest* y otros enfoques. Sin embargo, el reducido tamaño muestral limita la generalización de los resultados y subraya la necesidad de estudios con mayor poder estadístico⁽⁴⁸⁾.

Otro estudio exploró la reducción de dimensionalidad aplicada a 303 registros con 13 variables clínicas, optimizando la clasificación mediante distintos modelos. El KNN (k-vecinos más cercanos) mostró un desempeño superior, con precisiones de 83,8% en entrenamiento y 80% en prueba, respaldado por validación cruzada 10-fold. Estos resultados lo posicionan como una herramienta de utilidad en entornos clínicos con datos estructurados, aunque con un margen de mejora frente a

Tabla 3. Modelos de IA aplicados al diagnóstico por biomarcadores cardiovasculares

Grupo de estudios	Modelos predominantes	Modalidad / tipo de datos	Aprendizaje	Estrategia de validación
Modelos clásicos y de ensemble en datos clínicos y de laboratorio ^(46,47)	Árboles de decisión, Random Forest, Gradient Boosting y modelos combinados	Variables clínicas estructuradas	Supervisado	Validación cruzada interna
Algoritmos en cohortes pequeñas y datos estructurados ^(48,49)	Gradient Boosting, Random Forest, y KNN	Datos clínicos básicos (edad, PA, colesterol)	Supervisado	Validación cruzada 10-fold
Integración proteómica y clínica a gran escala ⁽⁶⁾	Explainable Boosting Machine y LightGBM	Datos proteómicos + clínicos	Supervisado con interpretabilidad	Validación en biobanco poblacional (UK Biobank)

KNN: k-vecinos más cercanos. Light GBM: máquina ligera de potenciación por gradiente. PA: presión arterial. UK: United Kingdom

algoritmos más complejos ⁽⁴⁹⁾.

La integración de biomarcadores proteómicos y datos clínicos ha ampliado las perspectivas de predicción del riesgo cardiovascular. En un análisis del UK Biobank que incorporó perfiles sanguíneos y variables clínicas, el uso del *Explainable Boosting Machine* permitió generar un modelo con AUROC de 0,767 y AUPRC (área bajo la curva *precision-recall*) de 0,2405 al considerar únicamente datos proteómicos. La inclusión de información clínica mejoró las métricas hasta 0,785 y 0,2835, respectivamente, superando a modelos tradicionales y a algoritmos de *machine learning* como LightGBM (máquina ligera de potenciación por gradiente) ⁽⁶⁾ (Tabla 3).

Discusión

Los avances en IA aplicados al diagnóstico cardiovascular muestran un impacto clínico creciente, aunque con matices en su aplicabilidad y confiabilidad. En ecocardiografía, la segmentación automática de cavidades ha alcanzado métricas de precisión que superan de forma consistente a la práctica manual, con coeficientes *Dice* cercanos a 0,93 y capacidad de cálculo automático de la fracción de eyección en grandes cohortes. Los resultados mostrados sugieren utilidad en la práctica rutinaria, especialmente para reducir la variabilidad interobservador, aunque persisten limitaciones en pacientes con FA o imágenes de baja calidad ^(14,15).

La detección automatizada de disfunción ventricular mediante datos no invasivos ha demostrado áreas bajo la curva superiores a 0,90 en poblaciones de más de 100 000 pacientes, lo que representa un salto en escalabilidad diagnóstica. Su mayor fortaleza radica en la capacidad de cribado poblacional, aunque la especificidad en subgrupos clínicamente complejos puede comprometer la aplicabilidad en decisiones individuales ^(19,20).

En RM y TC los algoritmos de aprendizaje profundo y métodos *kernel* han mostrado precisiones superiores al 85% en detección de isquemia y cuantificación de fibrosis. Sin embargo, la caída de rendimiento en validaciones externas y la heterogeneidad en tamaños muestrales evidencian la necesidad de protocolos de validación multicéntrica antes de su adopción clínica. Su principal aporte radica en la objetividad y reproducibilidad, aunque la confiabilidad aún depende de la estandarización ^(23,26).

Los enfoques multimodales han sido los más consistentes en términos de impacto clínico. La fusión de modalidades de imagen y datos clínicos ha reportado áreas bajo la curva cercanas a 0,92, superando de forma significativa a los *scores* de riesgo convencionales y confirmando un valor añadido en la estratificación pronóstica. La capacidad de integrar distintas fuentes de información representa un avance hacia modelos de apoyo a la decisión clínica con aplicabilidad real en escenarios hospitalarios ^(11,29).

El análisis de señales ha mostrado un rendimiento sobresaliente en FA, con un AUROC cercano al 0,99 en registros *Holter* y explicabilidad alineada con criterios clínicos, lo que respalda su fiabilidad y abre posibilidades para la detección temprana en atención primaria. No obstante, la generalización a diferentes dispositivos y contextos clínicos sigue siendo un desafío ^(33,35). En cardiopatía isquémica, modelos basados en

ECG y VCG alcanzaron precisiones superiores al 90% y validación frente a angiografía coronaria, lo que demuestra aplicabilidad en contextos de cribado, aunque la traducción a la práctica clínica requerirá validación prospectiva ^(37,38).

La fonocardiografía asistida por inteligencia artificial ha superado la precisión diagnóstica de médicos generales en valvulopatías, con sensibilidades mayores al 94%. Su confiabilidad se ve reforzada por validaciones prospectivas frente a ecocardiografía, lo que posiciona a estas herramientas como complementos útiles en entornos de atención primaria y mHealth (*mobile health*), con capacidad de cribado masivo ^(39,42).

En el ámbito de biomarcadores, los modelos de *machine learning* aplicados a datos de laboratorio alcanzaron precisiones cercanas al 98% en cohortes amplias, con consistencia en validaciones cruzadas, lo que respalda su valor en contextos preventivos. Sin embargo, el tamaño muestral reducido en algunos estudios limita la confiabilidad de ciertos hallazgos ^(46,48). La integración de la proteómica con variables clínicas en cohortes poblacionales mejoró la predicción de riesgo cardiovascular y permitió identificar biomarcadores candidatos de forma interpretable, lo que refuerza su aplicabilidad en medicina personalizada y en estrategias de prevención primaria ⁽⁶⁾.

La aplicación de IA al diagnóstico cardiovascular representa un avance relevante hacia una medicina más precisa, accesible y eficiente, aunque persisten desafíos que condicionan su implementación clínica. Las implicancias médicas de esta tecnología incluyen la posibilidad de estandarizar la interpretación diagnóstica, optimizar la detección temprana de enfermedades y reducir la variabilidad interobservador, pero su impacto real dependerá de validaciones multicéntricas que aseguren la reproducibilidad en poblaciones heterogéneas y contextos asistenciales diversos.

Por otro lado, la falta de explicabilidad en algunos modelos continúa limitando su aceptación entre los profesionales de la salud, pues dificulta la interpretación clínica y la toma de decisiones compartida. Además, se evidencian vacíos de evidencia en torno al desempeño longitudinal, la interoperabilidad con los sistemas clínicos y la evaluación de desenlaces duros. Superar estas limitaciones requerirá estudios prospectivos, transparencia algorítmica y una integración ética y regulatoria que respalde su uso responsable en la práctica cardiovascular.

Debido al carácter narrativo del artículo, se presentan limitaciones metodológicas, entre ellas el posible sesgo de publicación y la heterogeneidad de los estudios incluidos. No se realizó metaanálisis ni evaluación formal del riesgo de sesgo, por lo que los hallazgos deben interpretarse como una síntesis crítica de la evidencia disponible. Estas restricciones limitan la inferencia cuantitativa, aunque permiten identificar tendencias y vacíos relevantes para futuras investigaciones clínicas.

En conclusión, las métricas de desempeño demuestran un potencial transformador en escalabilidad, precisión y eficiencia diagnóstica. Sin embargo, la aplicabilidad clínica plena depende de validaciones multicéntricas, interoperabilidad con flujos de trabajo reales y evidencia de impacto en desenlaces clínicos. La confiabilidad de estos modelos se fortalece con explicabilidad y consistencia en cohortes externas, condiciones necesarias para su incorporación en guías de práctica clínica.

De acuerdo con los resultados, la IA aplicada al diagnóstico cardiovascular muestra un potencial clínico significativo, pero su adopción plena requiere validaciones multicéntricas rigurosas que confirmen la reproducibilidad de los resultados en poblaciones diversas y entornos asistenciales reales. Asimismo, la explicabilidad de los modelos constituye un requisito indispensable para fortalecer la confianza clínica, facilitar la interpretación de decisiones algorítmicas y garantizar su integración ética y segura en la práctica médica. El avance futuro del campo dependerá de la combinación equilibrada entre desempeño técnico, transparencia y evidencia clínica robusta.

Contribución de los autores

FRZ: conceptualización, curación de datos, análisis formal, investigación, metodología, redacción borrador original, redacción revisión y edición.

Uso de la IA en el desarrollo del trabajo

Para el presente artículo se usó ChatGPT en su versión 4.0 para corregir errores ortográficos, de puntuación y mejorar la legibilidad. El prompt usado fue «corrige los errores de redacción y ortográficos del texto y de puntuación para mejorar la legibilidad». Luego de la respuesta, se revisó que se hubiera mantenido la información proporcionada por el autor. La herramienta no ha sido usada para la creación autónoma de contenido.

Referencias bibliográficas

1. Topol EJ. High-performance medicine: the convergence of human and artificial intelligence. *Nat Med*. 2019;25(1):44-56. doi: 10.1038/s41591-018-0300-7.
2. Shortliffe EH, Buchanan BG. A model of inexact reasoning in medicine. *Math. Biosci.* 1975;23(3-4):351-79. doi: 10.1016/0025-5564(75)90047-4.
3. Esteva A, Kuprel B, Novoa RA, Ko J, Swetter SM, Blau HM, *et al.* Dermatologist-level classification of skin cancer with deep neural networks. *Nature*. 2017;542(7639):115-8. doi: 10.1038/nature21056.
4. Yao X, Rushlow DR, Inselman JW, McCoy RG, Thatcher TD, Behnken EM, *et al.* Artificial intelligence-enabled electrocardiograms for identification of patients with low ejection fraction: a pragmatic, randomized clinical trial. *Nat Med*. 2021;27(5):815-9. doi: 10.1038/s41591-021-01335-4.
5. Kwon D, Kang H, Lee D, Kim YC. Deep learning-based prediction of atrial fibrillation from polar transformed time-frequency electrocardiogram. *PLoS ONE*. 2025;20(3):e0317630. doi: 10.1371/journal.pone.0317630.
6. Climente-González H, Oh M, Chajewska U, Hosseini R, Mukherjee S, Gan W, *et al.* Interpretable machine learning leverages proteomics to improve cardiovascular disease risk prediction and biomarker identification. *Commun Med*. 2025;5(1):170. doi: 10.1038/s43856-025-00872-0.
7. Yu AC, Mohajer B, Eng J. External Validation of Deep Learning Algorithms for Radiologic Diagnosis: A Systematic Review. *Radiol Artif Intell*. 2022;4(3):e210064. doi: 10.1148/ryai.210064.
8. Dietterich T. Overfitting and undercomputing in machine learning. *ACM Comput Surv*. 1995;27(3):326-7. doi: 10.1145/212094.212114.
9. Rajkomar A, Dean J, Kohane I. Machine Learning in Medicine. *N Engl J Med*. 2019;380(14):1347-58. doi: 10.1056/NEJMr1814259.
10. Berkebile JA, Inan OT, Beach PA. Wearable multimodal sensing for quantifying the cardiovascular autonomic effects of levodopa in parkinsonism. *Front Netw Physiol*. 2025;5:1543838. doi: 10.3389/fnetp.2025.1543838.
11. Pezel T, Toupin S, Bousson V, Hamzi K, Hovasse T, Lefevre T, *et al.* A Machine Learning Model Using Cardiac CT and MRI Data Predicts Cardiovascular Events in Obstructive Coronary Artery Disease. *Radiology*. 2025;314(1):e233030. doi: 10.1148/radiol.233030.
12. Obermeyer Z, Emanuel EJ. Predicting the Future — Big Data, Machine Learning, and Clinical Medicine. *N Engl J Med*. 2016;375(13):1216-9. doi: 10.1056/NEJMp1606181.
13. Collins FS, Varmus H. A New Initiative on Precision Medicine. *N Engl J Med*. 2015;372(9):793-5. doi: 10.1056/NEJMp1500523.
14. Lal S. TC-SegNet: robust deep learning network for fully automatic two-chamber segmentation of two-dimensional echocardiography. *Multimed Tools Appl*. 2024;83(2):6093-111. doi: 10.1007/s11042-023-15524-5.
15. Morales-Galan A, Lopez-Gutierrez P, Garrido-Oliver J, Dux-Santoy L, Majul H, Rivas Catoni L, *et al.* Artificial intelligence for automatic echocardiography image view detection and left ventricle segmentation and ejection fraction prediction. *Eur Heart J Cardiovasc. Imaging*. 2025;26(Supplement_1):jeae333.031. doi: 10.1093/ehjci/jeae333.031.
16. Arafati A, Morisawa D, Avendi MR, Amini MR, Assadi RA, Jafarkhani H, *et al.* Generalizable fully automated multi-label segmentation of four-chamber view echocardiograms based on deep convolutional adversarial networks. *J R Soc Interface*. 2020;17(169):20200267. doi: 10.1098/rsif.2020.0267.
17. Zamzmi G, Rajaraman S, Hsu LY, Sachdev V, Antani S. Real-time echocardiography image analysis and quantification of cardiac indices. *Med Image Anal*. 2022;80:102438. doi: 10.1016/j.media.2022.102438.
18. Geven BWM, Zhao D, Creamer SA, Dillon JR, Quill GM, Edwards NC, *et al.* Automated Quality-Controlled Left Heart Segmentation from 2D Echocardiography. In: Camara Q, Puyol-Antón E, Sermesant M, Suinesiaputra A, Tao Q, Wang C, *et al.*, editors. *Statistical Atlases and Computational Models of the Heart Regular and CMR-Recon Challenge Papers* [Internet]. Cham: Springer Nature Switzerland; 2024 [citado el 16 de agosto de 2025]. p. 98-107. Disponible en: https://doi.org/10.1007/978-3-031-52448-6_10
19. Vaid A, Johnson KW, Badgeley MA, Somani SS, Bicak M, Landi I, *et al.* Using Deep-Learning Algorithms to Simultaneously Identify Right and Left Ventricular Dysfunction From the Electrocardiogram. *JACC Cardiovasc Imaging*. 2022;15(3):395-410. doi: 10.1016/j.jcmg.2021.08.004.
20. Lee E, Ito S, Miranda WR, Lopez-Jimenez F, Kane GC, Asirvatham SJ, *et al.* Artificial intelligence-enabled ECG for left ventricular diastolic function and filling pressure. *npj Digit Med*. 2024;7(1):4. doi: 10.1038/s41746-023-00993-7.
21. Zhang WL, Song B, Huang QJ, Quan WW, Zhang RY. Artificial intelligence for automated left ventricular systolic dysfunction detection using a wearable cardiac patch incorporated with synchronized phonocardiogram and electrocardiogram. *Eur Heart J*. 2024;45(Supplement_1):ehae666.3551. doi: 10.1093/eurheartj/ehae666.3551.
22. Shiraga T, Makimoto H, Kohlmann B, Magnisali CE, Imai Y, Itani Y, *et al.* Improving Valvular Pathologies and Ventricular Dysfunction Diagnostic Efficiency Using Combined Auscultation and Electrocardiography Data: A Multimodal AI Approach. *Sensors*. 2023;23(24):9834. doi: 10.3390/s23249834.
23. Muthulakshmi M, Kavitha G. Deep CNN with LM learning based myocardial ischemia detection in cardiac magnetic resonance images. In: 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) [Internet]. Berlin, Germany: IEEE; 2019 [citado el 16 de agosto de 2025]. p. 824-7. Disponible en: <https://doi.org/10.1109/EMBC.2019.8856838>

24. Cho GW, Sayed S, D'Costa Z, Karlsberg DW, Karlsberg RP. First comparison between artificial intelligence-guided coronary computed tomography angiography versus single-photon emission computed tomography testing for ischemia in clinical practice. *Coron Artery Dis.* 2025;36(5):390-5. doi: 10.1097/mca.0000000000001485.
25. Gonciar D, Berciu AG, Dulf EH, Orzan RI, Mocan T, Danku AE, *et al.* Computer-Assisted Algorithm for Quantification of Fibrosis by Native Cardiac CT: A Pilot Study. *J Clin Med.* 2024;13(16):4807. doi: 10.3390/jcm13164807.
26. Curiale AH, Cabrera F, Jimenez P, Medus J, Mato G, Calandrelli ME. Detection of Fibrosis in Cine Magnetic Resonance Images Using Artificial Intelligence Techniques. *arXiv.* 2022;arXiv:2206.01745. doi: 10.48550/arXiv.2206.01745.
27. Campese S, Agostini F, Sciarretta T, Pizzi M, Cipriani A, Zanetti M. Myocardial fibrosis detection using kernel methods: preliminary results from a cardiac magnetic resonance study. *Eur Heart J Cardiovasc. Imaging.* 2022;23(Supplement_2):jeac141.005. doi: 10.1093/ehjci/jeac141.005.
28. Michalski B, Skonieczka S, Strzelecki M, Simiera M, Kupczyńska K, Szymczyk E, *et al.* The use of artificial intelligence for predicting postinfarction myocardial viability in echocardiographic images. *Cardiol J.* 2024;31(5):699-707. doi: 10.5603/cj.93887.
29. Kumari SV, Lucas BR, Anitha C, Sangeetha SB, Santhi P, Raja RA, *et al.* Dense Residual Network-Powered Early Detection of Cardiovascular Diseases Using Multimodal Medical Imaging. *J Neonatal Surg.* 2025;14(65):175-86. doi: 10.52783/jns.v14.2221.
30. Patel KK, Kanodia A, Kumar B, Gupta R. Multi-Modal Data Fusion Based Cardiac Disease Prediction using Late Fusion and 2D CNN Architectures. In: 2024 11th International Conference on Signal Processing and Integrated Networks (SPIN) [Internet]. Noida, India: IEEE; 2024 [citado el 16 de agosto de 2025]. p. 279-84. Disponible en: <https://doi.org/10.1109/SPIN60856.2024.10512195>
31. Shen L, Zhang X, Huang S, Wu B, Li J. A diagnostic method for cardiomyopathy based on multimodal data. *Biomed Tech (Berl).* 2023;68(4):411-20. doi: 10.1515/bmt-2023-0099.
32. Mota D, Filho FNB, Sousa EB, Chagas RA, Sasaki EM, Candoti MW, *et al.* Comparative analysis of classical artificial intelligence and deep learning models for atrial fibrillation detection in electrocardiograms. *Europace.* 2024;26(Supplement_1):euae102.583. doi: 10.1093/europace/euae102.583.
33. Jin Y, Ko B, Chang W, Choi KH, Lee KH. Explainable paroxysmal atrial fibrillation diagnosis using an artificial intelligence-enabled electrocardiogram. *Korean J Intern Med.* 2025;40(2):251-61. doi: 10.3904/kjim.2024.130.
34. Wu C, Hwang M, Huang TH, Chen YM, Chang YJ, Ho TH, *et al.* Application of artificial intelligence ensemble learning model in early prediction of atrial fibrillation. *BMC Bioinformatics.* 2021;22(S5):93. doi: 10.1186/s12859-021-04000-2.
35. Taniguchi H, Takata T, Takechi M, Furukawa A, Iwasawa J, Kawamura A, *et al.* Explainable Artificial Intelligence Model for Diagnosis of Atrial Fibrillation Using Holter Electrocardiogram Waveforms. *Int Heart J.* 2021;62(3):534-9. doi: 10.1536/ihj.21-094.
36. Zhong D, Huang L, Jin S, An Y, Zhu S, Li J. Automatic electrocardiograph diagnosis of myocardial ischemia with support vector machine. *Digit Med.* 2023;9(2):e00009. doi: 10.1097/DM-2023-00009.
37. Zhao X, Zhang J, Gong Y, Xu L, Liu H, Wei S, *et al.* Reliable Detection of Myocardial Ischemia Using Machine Learning Based on Temporal-Spatial Characteristics of Electrocardiogram and Vectorcardiogram. *Front Physiol.* 2022;13:854191. doi: 10.3389/fphys.2022.854191.
38. Braun T, Spiliopoulos S, Veltman C, Hergesell V, Passow A, Tenderich G, *et al.* Detection of myocardial ischemia due to clinically asymptomatic coronary artery stenosis at rest using supervised artificial intelligence-enabled vectorcardiography – A five-fold cross validation of accuracy. *J Electrocardiol.* 2020;59:100-5. doi: 10.1016/j.jelectrocard.2019.12.018.
39. Jiang Z, Song W, Yan Y, Li A, Shen Y, Lu S, *et al.* Automated valvular heart disease detection using heart sound with a deep learning algorithm. *Int J Cardiol Heart Vasc.* 2024;51:101368. doi: 10.1016/j.ijcha.2024.101368.
40. Ma S, Chen J, Ho JWK. An edge-device-compatible algorithm for valvular heart diseases screening using phonocardiogram signals with a lightweight convolutional neural network and self-supervised learning. *Comput Methods Programs Biomed.* 2024;243:107906. doi: 10.1016/j.cmpb.2023.107906.
41. Jamil S, Roy AM. An efficient and robust Phonocardiography (PCG)-based Valvular Heart Diseases (VHD) detection framework using Vision Transformer (ViT). *Comput Biol Med.* 2023;158:106734. doi: 10.1016/j.combiomed.2023.106734.
42. Rancier MA, Israel I, Monickam V, Prince J, Verschoore B, Currie C. Abstract 13244: Real World Evaluation of an Artificial Intelligence Enabled Digital Stethoscope for Detecting Undiagnosed Valvular Heart Disease in Primary Care. *Circulation.* 2023;148(Suppl_1). doi: 10.1161/circ.148.suppl_1.13244.
43. Begic E, Gurbeta Pokvic L, Begic Z, Begic N, Dedic M, Mrcic D, *et al.* From Heart Murmur to Echocardiography - Congenital Heart Defects Diagnostics Using Machine-Learning Algorithms. *Psychiatr Danub.* 2021;33(Suppl 13):236-46.
44. Xu C, Li X, Zhang X, Wu R, Zhou Y, Zhao Q, *et al.* Cardiac murmur grading and risk analysis of cardiac diseases based on adaptable heterogeneous-modality multi-task learning. *Health Inf Sci Syst.* 2023;12(1):2. doi: 10.1007/s13755-023-00249-4.
45. Özcan F. Rapid detection and interpretation of heart murmurs using phonocardiograms, transfer learning and explainable artificial intelligence. *Health Inf Sci Syst.* 2024;12(1):43. doi: 10.1007/s13755-024-00302-w.
46. Tonni SI, Alam MA, Sohel A, Khan C, Onik MdKR, Pranto IH. Predictive Modeling of Cardiovascular Disease Using Machine Learning: A Comparative Analysis. In: 2025 5th International Conference on Advanced Research in Computing (ICARC) [Internet]. Belihuloya, Sri Lanka: IEEE; 2025 [citado el 16 de agosto de 2025]. p. 1-6. Disponible en: <http://doi.org/10.1109/ICARC64760.2025.10963191>
47. Sembina G, Aitim A, Shaizat M. Machine Learning Algorithms for Predicting and Preventive Diagnosis of Cardiovascular Disease. In: 2022 International Conference on Smart Information Systems and Technologies (SIST) [Internet]. Nur-Sultan, Kazakhstan: IEEE; 2022 [citado el 16 de agosto de 2025]. p. 1-5. Disponible en: <http://doi.org/10.1109/SIST54437.2022.9945708>
48. Kumar HS, Sirapu T, T S, Penubaka KKR, Reddy PRKK, Supriya PL. Investigating the Prediction of Cardiovascular Diseases using Different Machine Learning Methods. In: 2025 International Conference on Intelligent Computing and Control Systems (ICICCS) [Internet]. Erode, India: IEEE; 2025 [citado el 16 de agosto de 2025]. p. 929-35. Disponible en: <https://doi.org/10.1109/ICICCS65191.2025.10985574>
49. Ekong A. Evaluation of Machine Learning Techniques Towards Early Detection of Cardiovascular Diseases. *American Journal of Artificial Intelligence.* 2023;7(1):6-16. doi: 10.11648/j.ajai.20230701.12.