

# Efectividad de la inteligencia artificial en el diagnóstico de cardiopatías congénitas en población pediátrica: una revisión sistemática

## Effectiveness of artificial intelligence in the diagnosis of congenital heart disease in pediatric population: a systematic review

Carlos Daniel Flórez Pacheco <sup>1</sup>, Sarah Córdoba Salgado <sup>2</sup>,  
PhD. Jorge Gómez Gómez <sup>3</sup>

<sup>1</sup> **Universidad de Córdoba**, Facultad de Ingeniería, Departamento de Ingeniería de Sistemas y Telecomunicaciones, Grupo SOCRATES, Montería, Córdoba, Colombia, ORCID: 0009-0009-3382-7964, cflorezpacheco51@correo.unicordoba.edu.co

<sup>2</sup> **Universidad de Córdoba**, Facultad de Ingeniería, Departamento de Ingeniería de Sistemas y Telecomunicaciones, Grupo SOCRATES, Montería, Córdoba, Colombia, ORCID: 0009-0009-3919-4387, scordobasalgado66@correo.unicordoba.edu.co

<sup>3</sup> **Universidad de Córdoba**, Facultad de Ingeniería, Departamento de Ingeniería de Sistemas y Telecomunicaciones, Grupo SOCRATES, Montería, Córdoba, Colombia, ORCID: 0000-0001-8746-9386, jeliyecergomez@correo.unicordoba.edu.co

**Cómo citar:** Flórez Pacheco, C. D., Córdoba Salgado, S., & Gómez Gómez, J. (2026). Efectividad de la inteligencia artificial en el diagnóstico de cardiopatías congénitas en población pediátrica: una revisión sistemática. *Ingeniería, Sostenibilidad Y Sociedad*, 1(7), 1–18. <https://doi.org/10.24054/iss.v1i7.4473>

**Editorial:** Universidad de Pamplona.

**Recibido:** 8/diciembre/2025

**Aprobado:** 19/abril/2026

**Publicado:** 5/mayo/2026



**Resumen:** Las cardiopatías congénitas (CHD) representan un desafío clínico global debido a su complejidad anatómica y la alta dependencia del operador durante su diagnóstico, lo que genera brechas significativas en la detección, especialmente en entornos con recursos limitados. Esta revisión sistemática tuvo como objetivo evaluar la efectividad de la inteligencia artificial (IA) en el diagnóstico de CHD en población pediátrica. Tras analizar 14 estudios publicados entre 2020 y 2025, que abarcaron modalidades como ecocardiografía, electrocardiografía (ECG), fonocardiografía y radiografía, se evidenció un predominio de algoritmos de aprendizaje profundo (Deep Learning). Los resultados demostraron un rendimiento diagnóstico global elevado. La ecocardiografía destacó como la modalidad más efectiva, alcanzando precisiones de hasta el 100% y un AUC de 0.99, superando ampliamente la sensibilidad del tamizaje comunitario tradicional. Asimismo, el análisis automatizado de ECG emergió como una herramienta potente para el triaje masivo. En términos comparativos, la IA igualó o superó el desempeño de médicos generales en tareas de detección, aunque las comparaciones directas con cardiólogos expertos siguen siendo

limitadas. No obstante, la evidencia presenta limitaciones metodológicas notables, como un marcado sesgo hacia diseños retrospectivos, una alta concentración geográfica en Asia y una falta de estandarización en el reporte de datos. En conclusión, la IA posee un alto potencial para transformar el tamizaje, el triaje y el apoyo diagnóstico de las CHD. Sin embargo, su traslación clínica requiere urgentemente de validaciones prospectivas multicéntricas, mayor transparencia algorítmica y la adopción rigurosa de guías éticas y de reporte (como STARD-AI y TRIPOD+AI).

**Palabras clave:** cardiopatías congénitas, inteligencia artificial, machine learning, deep learning, diagnóstico, ecocardiografía, revisión sistemática.

**Abstract:** Congenital heart disease (CHD) presents a global clinical challenge because of its anatomical complexity and high operator dependence during diagnosis, leading to significant gaps in detection, especially in resource-limited settings. This systematic review aimed to evaluate the effectiveness of artificial intelligence (AI) in diagnosing CHD in the pediatric population. After analyzing 14 studies published between 2020 and 2025, encompassing modalities such as echocardiography, electrocardiography (ECG), phonocardiography, and radiography, a predominance of deep learning algorithms was observed. The results demonstrated a high overall diagnostic performance. Echocardiography stood out as the most effective modality, achieving accuracies of up to 100% and an AUC of 0.99, significantly exceeding the sensitivity of traditional community screening methods. Furthermore, automated ECG analysis has emerged as a powerful tool for mass triage. AI has matched or surpassed the performance of general practitioners in screening tasks, although direct comparisons with expert cardiologists remain limited. However, the evidence presents notable methodological limitations, such as a marked bias toward retrospective designs, a high geographic concentration in Asia, and a lack of standardization in the data reporting. In conclusion, AI has a high potential to transform screening, triage, and diagnostic support for coronary heart disease. However, its clinical translation urgently requires prospective multicenter validation, greater algorithmic transparency, and rigorous adoption of ethical and reporting guidelines (such as STARD-AI and TRIPOD+AI).

**Keywords:** congenital heart diseases, artificial intelligence, machine learning, deep learning, diagnosis, echocardiography, systematic review.

## 1. INTRODUCCIÓN

Las cardiopatías congénitas (CHD, por sus siglas en inglés) constituyen el grupo más frecuente de malformaciones estructurales al nacimiento y representan un desafío de salud pública global con una prevalencia estimada de 8 a 12 por cada 1,000 nacidos vivos (Hoffman & Kaplan, 2002; Wu et al., 2020; Zimmerman et al., 2020). En 2021, se registraron más de 4,18 millones de casos prevalentes en niños menores de cinco años a nivel mundial, lo que refleja

un incremento del 3,4% desde 1990, principalmente atribuible al crecimiento poblacional y la mejora en las capacidades diagnósticas (Xu et al., 2025).

La mortalidad asociada a CHD ha experimentado una reducción significativa del 56.2% entre 1990 y 2021, con 204.223 muertes globales reportadas en 2021. Sin embargo, esta reducción no ha sido uniforme: mientras que en regiones de alto índice sociodemográfico (SDI) la mortalidad

ha disminuido más del 75%, en países de bajos recursos CHD se está consolidando como una causa líder de mortalidad neonatal e infantil (Chowdhury et al., 2024; Xu et al., 2025; Ye et al., 2025).

En América Latina y el Caribe, la prevalencia estimada oscila entre 8 y 13 casos por cada 1.000 nacidos vivos, lo que representa más de 60.000 nacimientos anuales con cardiopatías congénitas. De este grupo, se estima que menos del 10% recibe atención oportuna en regiones de bajos recursos, resultando en una mortalidad del 30% durante el primer año de vida y secuelas graves en casi la mitad de los sobrevivientes (Araujo, 2025). En Colombia, los sistemas de vigilancia del Instituto Nacional de Salud (INS) han reportado recientemente que las cardiopatías congénitas son el defecto más frecuente en el país, con una prevalencia notificada de 79,9 casos por cada 10.000 nacidos vivos en menores de un año (Instituto Nacional de Salud, 2025).

El diagnóstico de CHD enfrenta múltiples desafíos derivados de su complejidad anatómica y su naturaleza altamente operador-dependiente, lo cual exige un nivel de especialización crítico para evitar errores interpretativos (Araujo, 2025; Nurmaini et al., 2021; Nova et al., 2021; Puchalski et al., 2019; The International Society of Ultrasound in Obstetrics, 2013; Wang et al., 2021). Si bien la ecocardiografía fetal puede alcanzar tasas de detección del 80% al 84% cuando se incluyen vistas de los tractos de salida y tres vasos, e incluso superar el 98% en manos de cardiólogos fetales expertos (Nurmaini et al., 2021, 2022), estas cifras no reflejan la realidad de la práctica general. En entornos comunitarios o de recursos limitados, la sensibilidad diagnóstica desciende drásticamente a un rango de entre 30% y 50% (Arnaout et al., 2018; Nurmaini et al., 2021). Esta brecha se atribuye principalmente a que más del 96% de los tamizajes prenatales son realizados por obstetras generales en lugar de especialistas, limitando la capacidad de identificar defectos complejos

durante la evaluación rutinaria (Arnaout et al., 2018; Han et al., 2024; Nurmaini et al., 2022).

La variabilidad inter e intra-observador en la interpretación de estudios por imágenes cardiovasculares representa una limitación adicional. Ciertos defectos, como la coartación aórtica, son notoriamente difíciles de detectar prenatalmente, con tasas de detección inferiores al 28% (Edwards et al., 2024; Li et al., 2024; Nurmaini et al., 2021; Pozza et al., 2024; Santhoshi et al., 2024).

La IA ha evolucionado desde aplicaciones experimentales hasta herramientas clínicas en cardiología pediátrica. Los algoritmos de deep learning, particularmente las redes neuronales convolucionales (CNN), han demostrado capacidad para extraer características complejas de imágenes médicas de manera automatizada, superando en algunos casos el desempeño de métodos tradicionales y, ocasionalmente, de especialistas humanos (Chen et al., 2020; Esteva et al., 2019; Khan et al., 2024; Leone et al., 2024; Petmezas et al., 2022; Topol, 2019; Wang et al., 2021). No obstante, ante la heterogeneidad de los estudios actuales, resulta indispensable sistematizar la evidencia disponible para determinar su utilidad clínica real.

Por lo tanto, el objetivo de esta revisión sistemática es evaluar la efectividad de la inteligencia artificial en el diagnóstico de cardiopatías congénitas, sintetizando la evidencia sobre su exactitud diagnóstica. Específicamente, este estudio busca: (1) identificar las arquitecturas de IA y tipos de datos predominantes; (2) contrastar las métricas de sensibilidad y especificidad de estos modelos frente al desempeño de especialistas humanos; y (3) evaluar la robustez y el riesgo de sesgo de los estudios reportados, con el fin de establecer el estado actual de esta tecnología como herramienta de apoyo clínico.

## 2. METODOLOGÍA

### 2.1. Diseño del estudio

Se realizó una revisión sistemática de literatura científica orientada a sintetizar la evidencia disponible sobre el desempeño de sistemas de inteligencia artificial (IA) en el diagnóstico y tamizaje de cardiopatías congénitas en población pediátrica, considerando distintas modalidades diagnósticas (p. ej., ecocardiografía, ECG, señales de auscultación y datos clínicos). El diseño del estudio siguió un protocolo estructurado de búsqueda, selección y extracción de datos.

## 2.2. Criterios de Elegibilidad

La selección de los estudios se guio por el marco PICO (Población, Intervención, Comparación, Resultados). Esta metodología permite estructurar la búsqueda de evidencia de manera precisa y evitar sesgos en la selección de la literatura (da Costa Santos et al., 2007; Martínez Díaz et al., 2016; Munn et al., 2018).

Los componentes definidos fueron:

**Población:** pacientes pediátricos (0–18 años) con sospecha o diagnóstico de cardiopatía congénita.

**Intervención:** algoritmos de IA (machine learning, deep learning, redes neuronales) aplicados al diagnóstico o clasificación de cardiopatías congénitas.

**Comparación:** métodos diagnósticos tradicionales y/o evaluación por especialistas (p. ej., cardiólogos pediatras, radiólogos) cuando el estudio lo reporta.

**Resultados (Outcomes):** métricas de desempeño diagnóstico cuantitativas: exactitud (accuracy), sensibilidad, especificidad, AUC-ROC y, cuando esté disponible, valores predictivos (VPP/VPN) u otras métricas reportadas (F1-score, precision/recall). Para estudios basados en visión por computadora (segmentación y detección), se incluyeron métricas de superposición y precisión espacial como Intersection over Union (IoU/Jaccard Index), Coeficiente Dice (F1-score en

segmentación) y mean Average Precision (mAP).

## 2.3. Criterios de Inclusión

- Estudios publicados entre enero de 2020 y diciembre de 2025.
- Estudios originales que evalúen algoritmos de IA/ML/DL para diagnóstico de CHD.
- Población exclusiva o mayoritariamente pediátrica (0-18 años).
- Estudios que reporten al menos una métrica de rendimiento cuantitativa (precisión, sensibilidad, especificidad, AUC).
- Publicaciones en inglés o español
- Estudios de validación clínica, retrospectivos o prospectivos.

## 2.4. Criterios de exclusión

- Estudios con población no pediátrica (adultos) o en los que la muestra pediátrica no pudiera separarse claramente.
- Revisiones, editoriales, cartas, opiniones, protocolos sin resultados, resúmenes sin texto completo, y literatura no original (a menos que se use solo para rastreo de referencias).
- Estudios que no abordaran cardiopatías congénitas o no aplicaran IA al objetivo diagnóstico.
- Estudios sin reporte de métricas cuantitativas mínimas de desempeño.
- Duplicados entre bases de datos.

## 2.5. Fuentes de Información

Se realizó una búsqueda sistemática en las siguientes bases de datos electrónicas:

- SCOPUS
- PubMed
- Google Scholar

La estrategia de búsqueda combinó términos relacionados con:

Cardiopatías congénitas: "congenital heart disease", "congenital heart defect", "CHD", "congenital cardiac anomal\*"

Inteligencia artificial: "artificial intelligence", "machine learning", "deep learning", "neural network\*", "AI", "ML", "DL"

Población pediátrica: "pediatric", "paediatric", "child\*", "infant", "neonatal", "newborn"

## 2.6. Proceso de selección de estudios

Los resultados fueron exportados a Mendeley y se eliminaron duplicados. Posteriormente, se realizó un cribado por título/resumen y luego evaluación a texto completo según los criterios de inclusión/exclusión. La selección fue realizada por 2 revisores, resolviendo discrepancias por consenso.

## 2.7. Extracción de datos

De cada estudio incluido se extrajeron, cuando estuvieran disponibles:

- Año, país/entorno clínico, diseño del estudio.
- Población (edad, n), tipo(s) de cardiopatía congénita evaluada(s).
- Modalidad diagnóstica (eco, ECG, RM, TC, RX, etc.).
- Tipo de IA (DL/CNN, SVM, Random Forest, otros), arquitectura/modelo reportado.
- Partición y validación (train/test, validación interna/externa).
- Comparador (especialista/método convencional) si aplica.
- Métricas: accuracy, sensibilidad, especificidad, AUC-ROC (Fawcett, 2006; Powers, 2020). Para estudios basados en visión por computadora (segmentación), se incluyeron métricas de superposición espacial como el Intersection over Union (IoU) y el Coeficiente Dice (Taha & Hanbury, 2015).

## 2.8. Síntesis de Datos

Se realizó una extracción estandarizada de información por estudio: país/entorno, diseño, tamaño muestral, rango etario, tipo de CHD, modalidad diagnóstica, descripción del modelo (tipo de algoritmo y arquitectura cuando se reportó), definición de la prueba índice y del estándar de

referencia, comparadores clínicos (si existían), y métricas de desempeño (accuracy, sensibilidad, especificidad, AUC, entre otras).

Dada la heterogeneidad esperada (modalidades, algoritmos, definiciones de caso, particiones de entrenamiento/validación y métricas), se utilizó una síntesis narrativa (Popay et al., 2006), complementada con tablas descriptivas. Cuando fue posible, se reportaron rangos y promedios (no meta-análisis) y se efectuó un análisis exploratorio de sensibilidad tipo "one-out" para valorar estabilidad de hallazgos. La síntesis se estratificó por: (1) modalidad (p. ej., ecocardiografía (Jiang et al., 2023; Wang et al., 2021), ECG (Lee et al., 2025), fonocardiografía/sonidos cardiacos (Liu et al., 2022; Wang et al., 2020); (2) tipo de enfoque (ML vs DL); (3) tipo de CHD; y (4) grupo etario.

Para los estudios que emplearon técnicas de visión por computadora destinadas a la segmentación de estructuras cardiacas o detección de anomalías anatómicas, se priorizó el análisis del Dice Coefficient y IoU como indicadores de precisión en la delimitación espacial, y el mAP para la capacidad del modelo de localizar múltiples defectos en una misma imagen (Taha & Hanbury, 2015; Zou et al., 2004).

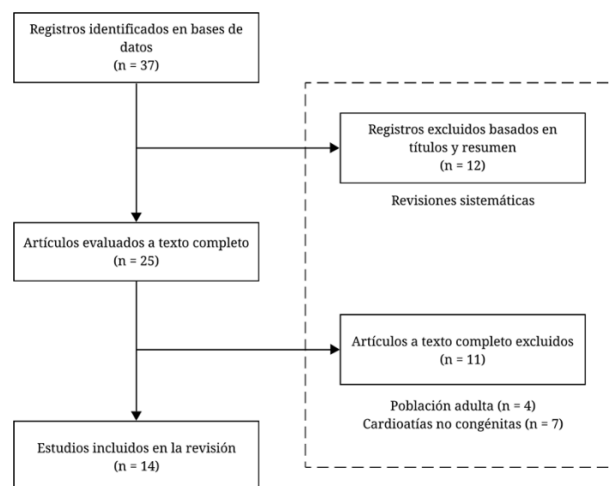
La metodología debe describir con precisión el diseño del estudio, los datos, herramientas y procedimientos empleados, de forma que garantice la reproducibilidad. Debe especificarse el tipo de enfoque (experimental, computacional, simulación, modelado u observacional), los criterios de selección de datos o sistemas de estudio y, cuando aplique, el tamaño y características de la muestra. Se deben detallar los instrumentos, tecnologías o plataformas utilizadas, incluyendo sus especificaciones relevantes. El procedimiento debe exponer claramente las etapas del desarrollo o implementación. El análisis debe indicar los métodos utilizados, software o entornos de trabajo y métricas de

evaluación. Cuando corresponda, debe considerarse el cumplimiento de normativas técnicas, estándares y aspectos éticos o de sostenibilidad asociados.

### 3. RESULTADOS

#### 3.1. Selección de Estudios

El proceso de búsqueda sistemática permitió identificar un total de 37 registros en las bases de datos consultadas. Durante la fase de cribado preliminar por título y resumen, se excluyeron 12 registros por no cumplir con los criterios de elegibilidad (correspondientes a revisiones sistemáticas y literatura no primaria).  
detalla en la Figura 1.



**Figura 1.** Diagrama de flujo del proceso de selección de estudios.

**Fuente:** Autores

#### 3.2.1. Distribución Temporal y Geográfica

Los estudios incluidos fueron publicados en el periodo reciente (2020–2025), evidenciando un crecimiento exponencial en la investigación sobre IA aplicada a cardiopatías congénitas. Geográficamente, se observó un claro predominio asiático: el 57.14% de las investigaciones (n=8) provienen de China, seguidas por estudios de Indonesia. Por su parte, Estados Unidos, Países Bajos, Taiwán y Corea del Sur contribuyeron con una única publicación cada uno, lo que refleja el

Consecuentemente, se recuperaron 25 textos completos para su evaluación detallada. En esta etapa, se excluyeron 11 estudios debido a las siguientes razones:

#### 3.2. Población adulta:

Evaluación de cardiopatías no congénitas ().

Finalmente, un total de 14 estudios cumplieron con todos los criterios de inclusión y fueron incorporados en la síntesis cualitativa y cuantitativa de la presente revisión.

liderazgo tecnológico de la región Asia-Pacífico en este nicho específico.

#### 3.2.2. Características Metodológicas

En términos de diseño de estudio, el 50% fueron retrospectivos, el 7% prospectivos, y el 43% estudios de desarrollo y validación diagnóstica. El tamaño de muestra varió entre 50 y 93,127 pacientes/Imágenes, con una mediana de 913. Las características generales de los estudios incluidos se detallan en la Tabla 1.

Tabla I. características de los estudios incluidos.

Autor (Año)	País	Diseño del Estudio	Muestra (N)	Modalidad	Objetivo
Nurmani et al. (2021)	Indonesia	Observacional analítico, transversal (hospital único)	50 (1149 imágenes)	Eco	Segmentación de vistas estándar + detección CHD (Mask R-CNN, multi-task)
Athalye et al. (2024) Click or tap here to enter text.	Países Bajos	Retrospectivo (entorno comunitario; test externo)	108 estudios US	Eco	Tamizaje prenatal normal vs CHD (Ensamble DL: detección de vista + decisión + agregación)
Jiang et al. (2023) [34]	China	Retrospectivo, single-center	1376 (14838 imágenes)	Eco	Detección/clasificación CHD vs normal en 7 vistas (ResNet50)
Nurmani et al. (2022)	Indonesia	Diagnóstico (tamizaje prenatal US; escenarios intra/inter)	76 (1129+55 frames)	Eco	Clasificación CHD (7 CHD + normal) y apoyo diagnóstico (DenseNet201 + XAI)
Park et al. (2024)	Rep. de Corea	Retrospectivo (EHR en NICU)	409 (4726 muestras)	EHR + eco	Detección/clasificación PDA sintomático vs asintomático (Random Forest)
Wang et al. (2020)	China	Registros hospitalarios/centros de salud (PCG)	86 (86 PCG)	PCG	Clasificación: normal vs murmullo CHD (ANN; 3 capas)
Liu et al. (2022)	China	Centro único (hospital pediátrico)	884 grabaciones (475 CHD + 409 ctrl)	Sonidos cardiacos	Clasificación por tipo de shunt y vs auscultación experta (RCRnet)
Chen et al. (2024)	China	Retrospectivo multicéntrico (2 tests externos)	93,127 ECG	ECG	Detección CHD (binaria) + subtipos por fine-tuning (conv1D + Transformer + atención)
Lee et al. (2025)	Taiwán	Retrospectivo, single-center	1,035 ECG	ECG	Predicción CHD clínicamente significativa <5 años (CWT + CNN; mejor ResNet-18)
Cheng et al. (2024)	China	2 grupos clínicos; within-center + cross-center	1,932 (TTE multi-vista)	Eco	Detección/cribado CHD (normal vs CHD; ASD/VSD) con fusión multi-vista/multi-modal (ResNet18 + FCNN)

Wang et al. (2021)	China	Dataset hospitalario; patient-independent split	1,308 sujetos	Eco	Interpretación automática multi-vista (binaria y 3-clase: ASD/VSD/neg) con CNN + agregación temporal
Karimi-Bidhendi et al.	USA	Retrospectivo (CMR pediátrica)	64 estudios	MRI/CMR	Segmentación automática LV/RV (FCN/FCN-SAD + DCGAN)
Han et al. (2024)	China	Retrospectivo + MRMC (lectores)	3255 RX (test balanceado o 330)	CXR	Diagnóstico asistido: CHD vs no-CHD y PAH-CHD (ResNet18)
Xu et al. (2022)	China	Desarrollo/evaluación con estetoscopio electrónico	941 señales PCG	PCG	Clasificación CHD vs normal y subtipos (features + voting con RF/Adaboost; 5-fold CV)

Fuente: Autores

### 3.2.3. Tipos de Cardiopatías Congénitas Evaluadas

Los tipos de CHD más frecuentemente estudiados fueron los defectos septales, consolidándose como el foco principal de la investigación actual en IA. Específicamente, tanto el defecto septal ventricular (VSD) como el defecto septal atrial (ASD) fueron las patologías más prevalentes, siendo incluidas en el 71.4% de los estudios.

Les sigue en frecuencia el ductus arterioso persistente (PDA), abordado en el 50% de las investigaciones. Otras cardiopatías complejas tuvieron una representación menor en la muestra: la Tetralogía de Fallot (TOF) y los defectos del canal atrioventricular (AVSD) aparecieron en el 21.4% de los trabajos, mientras que patologías como la transposición de grandes arterias (TGA) o la doble salida del ventrículo derecho (DORV) fueron evaluadas en el 14.3% de los casos. Defectos como estenosis pulmonar, coartación de aorta o síndrome de corazón izquierdo hipoplásico fueron reportados únicamente en un estudio (7.1%) cada uno.

## 3.3. Modalidades Diagnósticas

### 3.3.1. Ecocardiografía

La ecocardiografía fue la modalidad predominante, abordada tanto en etapa prenatal como pediátrica.

En el ámbito fetal, la aplicación de Deep Learning ha demostrado ser efectiva para superar las limitaciones del tamizaje en entornos comunitarios. Athalye et al. (2024) validaron un modelo de ensamble en una cohorte retrospectiva, alcanzando una sensibilidad del 91%, superior a la evaluación clínica inicial. Por su parte, Nurmaini et al. (2021, 2022) se enfocaron en la segmentación automatizada de vistas estándar utilizando arquitecturas como Mask R-CNN y DenseNet201, reportando una precisión intra-paciente del 98% al 100% y demostrando robustez en escenarios inter-patient para la detección de defectos septales y críticos.

En población pediátrica, los estudios se orientaron al diagnóstico multicámara y multimodal. Jiang et al. (2023) y Cheng et al. (2024) desarrollaron modelos basados en CNN (ResNet) que integran múltiples vistas ecocardiográficas, logrando un AUC de 0.91 y 0.99 respectivamente. Destaca el enfoque de Wang et al. (2021) quienes, al utilizar análisis de videos y key-frames multi-vista en lugar de imágenes estáticas, alcanzaron una exactitud del 95.4% en la clasificación de defectos septales.

Adicionalmente, en el contexto de cuidados intensivos neonatales, Park et al. (2024) demostraron que el soporte de IA basado en Random Forest mejoró la detección temprana del Ductus Arterioso Persistente (PDA) en prematuros, incrementando la exactitud diagnóstica del 48% (sin IA) al 84% (con IA).

### 3.3.2. Electrocardiografía (ECG)

El análisis automatizado del ECG de 9 derivaciones emergió como una herramienta potente para el tamizaje masivo. El estudio multicéntrico de Chen et al. (2024), entrenado con más de 93.127 casos, desarrollaron el modelo CHDdECG, el cual integró características extraídas por Deep Learning con conceptos clínicos humanos. Este modelo alcanzó un AUC de 0.915, superando el desempeño de cardiólogos experimentados y demostrando una alta generalización en centros externos. En una cohorte más pequeña de menores de 5 años, Lee et al. (2025) utilizaron la transformada continua de Wavelet combinada con CNN para predecir cardiopatías hemodinámicamente significativas, reportando un AUC de 0.81.

### 3.3.3. Resonancia Magnética

La evidencia en Resonancia Magnética Cardiovascular se centró en la segmentación anatómica precisa para cardiopatías complejas. Karimi-Bidhendi et al. (2020) validaron una red totalmente convolucional (FCN) en pacientes con Tetralogía de Fallot y Transposición de Grandes Arterias. Su modelo logró un coeficiente Dice superior a 0.91 para la segmentación ventricular, superando a las herramientas de software comerciales

convencionales y facilitando la cuantificación volumétrica automatizada sin intervención manual.

### 3.3.4. Radiografía de Tórax y Otras Modalidades

Como una alternativa costo-efectiva para entornos de bajos recursos, Han et al. (2024) evaluaron el uso de algoritmos de Deep Learning (ResNet18) en radiografías de tórax frontales. El modelo demostró una capacidad notable para detectar cardiopatías congénitas con un AUC de 0.948 y una sensibilidad del 97%, además de identificar hipertensión arterial pulmonar asociada con un AUC de 0.778, mejorando significativamente la precisión diagnóstica de los radiólogos jóvenes asistidos por el algoritmo.

### 3.3.5. Fonocardiografía y Análisis de Sonidos Cardíacos

El análisis inteligente de la auscultación mostró resultados prometedores para el tamizaje no invasivo. Liu et al. (2022) desarrollaron la red RCRnet para identificar soplos asociados a cortocircuitos de izquierda a derecha (CIV, CIA, PCA), reportando una sensibilidad superior al 93%, la cual fue mayor que la obtenida por auscultación experta manual. De manera similar, Wang et al. (2020) y Xu et al. (2022) utilizaron redes neuronales y Random Forest sobre señales de estetoscopios electrónicos, alcanzando exactitudes diagnósticas entre 93% y 95% en la diferenciación de soplos patológicos versus inocentes.

## 3.4. Métricas de Rendimiento Global

### 3.4.1. Análisis Consolidado de Precisión

**Tabla II.** métricas de rendimiento por modalidad diagnóstica

Modalidad	N estudios	Precisión (Rango)	Sensibilidad (Rango)	Especificidad (Rango)	AUC Rango	Doi
Ecocardiografía	6	92.30–100.00%	91.00–100.00%	78.00–100.00%	0.910–0.990	(Athalye et al., 2024; Cheng et

						al., 2024; Jiang et al., 2023; Nurmaini et al., 2021, 2022; Wang et al., 2021)
ECG	2	73.90%	75.90–80.00%	71.50–88.10%	0.810–0.915	(Chen et al., 2024; Lee et al., 2025)
RM/TC	1	NA	91.70%	99.90%	NA	(Karimi-Bidhendi et al., 2020)
Radiografía	1	NA	97.00%	98.20%	0.948	(Han et al., 2024)
Otros	4	84.00–99.40%	71.00–100.00%	91.70–99.70%	NA	(Liu et al., 2022; Park et al., 2024; Wang et al., 2020; Xu et al., 2022)
Global	14	73.90–100.00%	71.00–100.00%	71.50–100.00%	0.810–0.990	-

Según la Tabla II. (resumen por modalidad), se incluyeron 14 estudios y la ecocardiografía fue la modalidad más frecuente (n=6), con desempeño alto (precisión/accuracy 92.3–100%, sensibilidad 91–100%, especificidad 78–100% y AUC 0.910–0.990). En ECG (n=2) el rendimiento fue más moderado (accuracy 73.9%, sensibilidad 75.9–80.0%, especificidad 71.5–88.1%, AUC 0.810–0.915). La radiografía (n=1) mostró AUC 0.948 con sensibilidad 97.0% y especificidad 98.2%, mientras que RM/TC (n=1) reportó sensibilidad 91.7% y especificidad 99.9% (AUC no informado). En conjunto, el rango global fue accuracy 73.9–100%, sensibilidad 71–100%, especificidad 71.5–100% y AUC 0.810–0.990.

#### 3.4.2. Autor (Año) Patología Evaluada Algoritmo Sensibilidad (%) Especificidad (%) AUC / Precisión

Nurmaini (2021) CHD fetal (ASD/VSD/AVSD) + vistas estándar Mask R-CNN (ResNet50) NA NA mAP 98.30% (intra) / 82.42% (inter)  
 Athalye (2024) Tamizaje prenatal CHD severa (normal vs CHD) Ensamble DL (detección de vista + decisión + agregación) 91 78 NA  
 Jiang (2023) CHD pediátrica (CHD vs normal) ResNet50 (transfer learning) NA NA AUC 0.91; Acc 92.3%

Nurmaini (2022) CHD prenatal mayores (7 CHD + normal) DenseNet201 99% (inter) / 100% (intra) 97% (inter) / 100% (intra) Acc 98% (inter) / 100% (intra)  
 Park (2024) PDA en prematuros (sintomático vs asintomático) Random Forest 71% (Recall) NA Acc 84%; Prec 42%  
 Wang (2020) Soplos por CHD (PCG; normal vs murmullo CHD) ANN (Levenberg-Marquardt) 93.5 91.7 Acc 93%  
 Liu (2022) CHD shunt I→D (ASD/VSD/PDA/mixta) RCRnet 93.2–100 94.4–99.7 Acc 94.0–99.4%; Prec 88.8–99.7%  
 Chen (2024) CHD pediátrica desde ECG (binaria; + fine-tuning subtipos) CHDdECG (Conv1D + Transformer + atención + TabBlocks) 80.0 (int) / 77.0–78.6 (ext) 88.1 (int) / 90.7–93.7 (ext) AUC 0.915 (int) / 0.907–0.917 (ext)  
 Lee (2025) CHD “significativa” <5 años (ECG 12 derivaciones) CWT + CNN (mejor: ResNet-18) 75.9 71.5 AUC 0.810; Acc 73.9%; F1 75.8%  
 Cheng (2024) CHD desde TTE multi-vista/multi-modal (screening) ResNet18 + FCNN (fusión) 97.9 96.4 AUC 0.990 (screening)  
 Wang (2021) ASD/VSD desde eco multi-vista CNN multi-canal (DSC + agregación temporal) NA NA AUC 0.942; Acc 95.4% (binaria)  
 Karimi-Bidhendi (2020) CHD compleja (CMR) – segmentación FCN / FCN-SAD

(+ DCGAN) NA NA Dice: LVED 0.910; LVES 0.868; RVED 0.847; RVES 0.806  
 Han (2024) CHD y PAH-CHD desde Rx tórax ResNet18 (pretrained) 97.0 (CHD) / 63.2 (PAH-CHD) 98.2 (CHD) / 92.5 (PAH-CHD) AUC 0.948 (CHD) / 0.778 (PAH-CHD)  
 Xu (2022) CHD desde PCG (CHD vs normal; ASD/PDA/PFO/VSD) Segmentación PCG + 84 features + voting (RF/Adaboost) 94.6 96.1 Acc 95.3%; F1 95.3%

### 3.5. Comparación IA vs. Especialistas

En los estudios que incluyeron un comparador humano, la IA se evaluó principalmente como herramienta de apoyo (second reader) o como tamizaje/triage para priorización de casos. En modalidades basadas en sonidos cardiacos (PCG), los enfoques de aprendizaje automático y profundo mostraron desempeños competitivos para diferenciar normalidad vs. soplos/CHD: Wang et al. (2020) y Xu et al. (2022) reportaron métricas elevadas para clasificación basada en PCG, mientras que Liu et al. (2022) aplicaron Deep Learning en análisis de sonidos cardiacos para CHD con shunt izquierda-derecha.

En ECG, los modelos orientados a detección de CHD en grandes cohortes mostraron resultados relevantes para comparación con expertos. Chen et al. (2024) desarrollaron un enfoque con validaciones externas, y Lee et al. (2025) aplicaron transformadas tiempo-frecuencia con CNN para predicción de CHD clínicamente significativa en menores de 5 años, evidenciando utilidad potencial como filtro inicial previo a ecocardiografía.

En ecocardiografía, las comparaciones se enfocaron en rendimiento diagnóstico respecto al estándar habitual de práctica. Athalye et al. (2024) reportaron un desempeño superior al flujo comunitario de detección prenatal, mostrando el rol de la IA para elevar sensibilidad en entornos no especializados. En escenarios pediátricos, Cheng et al. (2024) y Wang et al. (2021) integraron

múltiples vistas y/o señales complementarias para aproximarse al modo en que un especialista combina información multiproyecto.

Finalmente, en radiografía de tórax, Han et al. (2024) evaluaron un modelo con lectura comparativa (diseño multi-reader multi-case), sugiriendo que la IA puede funcionar como apoyo rápido en servicios con alta demanda.

En conjunto, la evidencia sugiere que la IA puede igualar o superar el rendimiento operativo tradicional en tareas acotadas (tamizaje binario, identificación de patrones), pero las comparaciones con especialistas suelen estar limitadas por: (i) variaciones en experiencia del lector, (ii) diferencias en el ground truth, y (iii) ausencia de evaluación prospectiva en flujo real de trabajo.

### 3.6. Tiempo de Procesamiento y Eficiencia

La eficiencia computacional se reportó de forma heterogénea, pero varios estudios destacaron inferencia rápida compatible con uso clínico. En ECG, Chen et al. (2024) y Lee et al. (2025) describen flujos automatizados que facilitan el tamizaje; en escenarios con datos clínicos, Park et al. (2024) emplearon Random Forest con variables rutinarias, reduciendo costo de adquisición y acelerando el triage inicial.

Para ecocardiografía y PCG, la latencia depende del pipeline (captura/calidad, segmentación/selección de vista y clasificación). Nurmaini et al. (2021, 2022) muestran que automatizar la selección/segmentación puede disminuir carga manual y acelerar el flujo diagnóstico, aunque aún se requiere estandarizar el reporte de tiempos para comparabilidad entre estudios.

## 4. DISCUSIÓN

Esta revisión sintetizó evidencia sobre la efectividad de la inteligencia artificial en el diagnóstico de cardiopatías

congénitas en población pediátrica, integrando 14 estudios seleccionados mediante un proceso de tamizaje con criterios de elegibilidad definidos. El conjunto final se caracterizó por una marcada concentración geográfica y un predominio de enfoques basados en aprendizaje profundo, lo cual resulta consistente con la tendencia contemporánea en diagnóstico médico asistido por IA.

#### 4.1. Síntesis de hallazgos por modalidad

Los resultados de esta revisión muestran que la IA aplicada al diagnóstico de CHD en población pediátrica (incluyendo prenatal) presenta desempeños globales altos, particularmente en ecocardiografía y en enfoques de ECG a gran escala (Athalye et al., 2024; Chen et al., 2024; Cheng et al., 2024; Jiang et al., 2023). La heterogeneidad de modalidades (Eco, ECG, PCG, CXR, CMR) evidencia que la IA puede actuar como capa transversal de apoyo clínico, aunque con diferencias en diseño y validación entre estudios (Han et al., 2024; Karimi-Bidhendi et al., 2020; Lee et al., 2025; Nurmaini et al., 2021; Wang et al., 2021).

#### 4.2. Comparación con especialistas y valor clínico incremental

Los hallazgos apuntan a tres usos principales: (1) tamizaje prenatal y pediátrico para aumentar sensibilidad en entornos comunitarios o con menor experiencia (Athalye et al., 2024); (2) triage para priorizar estudios y reducir tiempos de espera, especialmente en modalidades disponibles (ECG/CXR) (Han et al., 2024; Lee et al., 2025); y (3) soporte a la interpretación especializada mediante modelos multivista y segmentación, reduciendo variabilidad y estandarizando mediciones (Karimi-Bidhendi et al., 2020; Nurmaini et al., 2021, 2022; Wang et al., 2021). No obstante, el salto desde desempeño "en laboratorio" hacia impacto real exige evaluar decisiones clínicas, rutas de referencia, costos y seguridad del paciente.

#### 4.3. Calidad metodológica, generalización y brechas

Persisten limitaciones que afectan la generalización: predominio de diseños retrospectivos y monocéntricos, variación en criterios de inclusión (sesgo de espectro), y diferencias en estándares de referencia. Para revisiones de exactitud diagnóstica, es clave mapear sistemáticamente fuentes de sesgo y aplicabilidad con QUADAS-2 (Whiting et al., 2011) y mejorar transparencia de reporte con STARD 2015 (Bossuyt et al., 2015; Cohen et al., 2016). Además, el reporte incompleto de particiones de datos, filtrado de calidad y manejo de desbalance de clases puede inflar métricas y dificultar la replicación.

#### 4.4. Implicaciones para implementación

En población pediátrica y prenatal, la ética es central: legitimidad del uso secundario, anonimización, gobernanza de datos y mitigación de sesgo. Revisiones recientes sobre IA en CHD y en electrocardiografía pediátrica resaltan riesgos de privacidad, sesgo y responsabilidad clínica (Leone et al., 2024; Pozza et al., 2024). Desde la perspectiva de reporte y transparencia, guías contemporáneas recomiendan describir explícitamente la interacción humano-IA, manejo de entradas/salidas y análisis de fallos: CONSORT-AI (Liu et al., 2020) y SPIRIT-AI (Cruz Rivera et al., 2020). Para modelos predictivos/diagnósticos basados en ML, TRIPOD+AI orienta un reporte reproducible y evaluable (Collins et al., 2024). En exactitud diagnóstica centrada en IA, STARD-AI propone ítems mínimos adicionales para permitir evaluación crítica y comparación (Sounderajah et al., 2025).

En relación con "fuentes" (datos/código), la ausencia de disponibilidad pública o repositorios versionados reduce reproducibilidad. Se recomienda, cuando sea posible, publicar código versionado, releases archivados (DOI), y descripciones detalladas de cohortes y

preprocesamiento, sin comprometer privacidad.

#### 4.5. Líneas futuras

Las prioridades sugeridas por la evidencia incluyen: validación prospectiva y multicéntrica en flujo real; evaluación de equidad (subgrupos) y drift; integración multimodal (Eco + ECG + clínica); comparaciones estandarizadas con especialistas (p. ej., MRMC); y adopción sistemática de guías de reporte (STARD 2015/STARD-AI, QUADAS-2, CONSORT-AI/SPIRIT-AI, TRIPOD+AI) (Bossuyt et al., 2015; Cohen et al., 2016; Collins et al., 2024; Cruz Rivera et al., 2020; Liu et al., 2020; Sounderajah et al., 2025; Whiting et al., 2011).

### 5. CONCLUSIONES

La evidencia sintetizada sugiere que la IA aplicada al diagnóstico de CHD en población pediátrica puede alcanzar alto desempeño en múltiples modalidades, destacándose ecocardiografía prenatal/pediátrica y enfoques de ECG a gran escala (Athalye et al., 2024; Chen et al., 2024; Cheng et al., 2024), con potencial para tamizaje, triage y apoyo a la interpretación (Han et al., 2024; Lee et al., 2025; Nurmaini et al., 2021; Wang et al., 2021). Sin embargo, la traslación clínica depende de validación externa robusta, evaluación prospectiva, estandarización del reporte y un marco ético sólido que aborde privacidad, sesgo, transparencia y responsabilidad clínica (Bossuyt et al., 2015; Cohen et al., 2016; Collins et al., 2024; Cruz Rivera et al., 2020; Liu et al., 2020; Sounderajah et al., 2025; Whiting et al., 2011).

### 6. REFERENCIAS

Alvarez Morales, E. L., Guillin Llanos, X. M., & Rodríguez Angulo, D. E. (2021). Análisis de los efectos que produce la presencia del cadmio en el cultivo de cacao (*Theobroma cacao*). *Ingeniería e Innovación*, 9(2). <https://doi.org/10.21897/23460466.2723>

A. Bravo, Z. Nieto, J. Cristancho y L. Useche, «Perspectivas de investigación en torno a los ambientes de aprendizaje en el siglo XXI: una visión desde una región transfronteriza,» *Revista Colombiana de Tecnologías de Avanzada*, vol. 2, n° 42, pp. 150-157, 2023.

Aguirre Á, Álvarez P, Patiño M Redes sociales y la salud mental un análisis bibliométrico. *Revista de Ingenierías Interfaces* 2022; 5(1):1-30.

Araujo, J. J. (2025). Challenges in the transition and transfer of young adults with congenital heart disease in Latin America and the Caribbean: The "timeliness principle". *Congenital Heart Disease*, 20(1), 61–75.

Arnaout, R., Curran, L., Chinn, E., Zhao, Y., & Moon-Grady, A. (2018). Deep-learning models improve on community-level diagnosis for common congenital heart disease lesions [Resumen de conferencia].

A. J. B. Berrocal and D. M. C. Rizo, "Scientometric Analysis of the Relationship Between Artificial Intelligence and Data Engineering: Trends, Collaboration, and Evolution," *interfaces*, vol. 7, no. 2, 2024.

Arengas Acosta, J. M., Lopez Ramirez, M., & Guzman Cabrera, R. (2024). Impacto del preprocesamiento en la clasificación automática de textos usando aprendizaje supervisado y Reuters 21578. *Revista Colombiana de Tecnologías de Avanzada*, 1(43), 110–118.

<https://doi.org/10.24054/rcta.v1i43.2506>.

Arregocés, I., Ariza, M., Camargo, N., Díaz, J., & Gamarra, M. (2022). Integración de Scrum y RUP para el desarrollo de software de planes turísticos basado en preferencias de usuario. *Ingeniería e Innovación*. <https://revistas.unicordoba.edu.co/index.php/rri/article/view/2974>

Athalye, C., van Nesselrooij, A., Rizvi, S., Haak, M. C., Moon-Grady, A. J., & Arnaout, R. (2024). Deep-learning model

for prenatal congenital heart disease screening generalizes to community setting and outperforms clinical detection. *Ultrasound in Obstetrics & Gynecology*, 63(1), 44–52.

Bastidas, J. V., & Vera, J. M. (2020). Biocombustible sólido a partir de residuos que generan los procesos agroindustriales del sector El Empalme. *Ingeniería e Innovación*, 8(22). <https://doi.org/10.21897/23460466.2333>

Bossuyt, P. M., et al. (2015). STARD 2015: An updated list of essential items for reporting diagnostic accuracy studies. *The BMJ*, 351, h5527. <https://doi.org/10.1136/bmj.h5527>

Cardozo Rueda, K. S. (2022). Aplicación de redes neuronales artificiales para el pronóstico de precios de café. *Revista Colombiana de Tecnologías de Avanzada*, 1(39), 113–117. <https://doi.org/10.24054/rcta.v1i39.1403>.

Chen, C., et al. (2020). Deep learning for cardiac image segmentation: A review. *Frontiers in Cardiovascular Medicine*, 7, 25.

Chen, J., et al. (2024). Congenital heart disease detection by pediatric electrocardiogram based deep learning integrated with human concepts. *Nature Communications*, 15(1), 976.

Cheng, M., et al. (2024). Development and validation of a deep-learning network for detecting congenital heart disease from multi-view multi-modal transthoracic echocardiograms. *Research*, 7, 319.

Chowdhury, D., et al. (2024). Addressing disparities in pediatric congenital heart disease: A call for equitable health care. *Journal of the American Heart Association*, 13(13), e032415. <https://doi.org/10.1161/JAHA.123.032415>

C. A. Mejía Rodríguez, M. A. Rincón Pinzón, L. M. Palmera Quintero, and L. M. Arévalo Vergel, "Aplicación de machine learning y metodología CRISP-

DM para la clasificación precisa de severidad en casos de dengue," *Revista Colombiana de Tecnologías de Avanzada (RCTA)*, vol. 1, no. 43, pp. 78–85, Mar. 2024. [Online]. Available: <https://doi.org/10.24054/rcta.v1i43.2822>.

Cohen, J. F., et al. (2016). STARD 2015 guidelines for reporting diagnostic accuracy studies: Explanation and elaboration. *BMJ Open*, 6(11), e012799. <https://doi.org/10.1136/bmjopen-2016-012799>

Collins, G. S., et al. (2024). TRIPOD+AI statement: Updated guidance for reporting clinical prediction models that use regression or machine learning methods. *The BMJ*, 385, e078378. <https://doi.org/10.1136/bmj-2023-078378>

Cruz Rivera, S., et al. (2020). Guidelines for clinical trial protocols for interventions involving artificial intelligence: The SPIRIT-AI extension. *The Lancet Digital Health*, 2(10), e549–e560. [https://doi.org/10.1016/S2589-7500\(20\)30219-3](https://doi.org/10.1016/S2589-7500(20)30219-3)

da Costa Santos, C. M., de Mattos Pimenta, C. A., & Nobre, M. R. C. (2007). The PICO strategy for the research question construction and evidence search. *Revista Latino-Americana de Enfermagem*, 15(3), 508–511.

Díaz, M., Urdánigo, J., Mercedes, A., & Muñoz, R. (2020). Cultura ambiental en estudiantes de educación superior. *Ingeniería e Innovación*.

Edwards, L. A., et al. (2024). Building a machine learning-assisted echocardiography prediction tool for children at risk for cancer therapy-related cardiomyopathy. *Cardio-Oncology*, 10(1), 66.

Esteva, A., et al. (2019). A guide to deep learning in healthcare. *Nature Publishing Group*. <https://doi.org/10.1038/s41591-018-0316-z>

Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861–874.

<https://doi.org/10.1016/j.patrec.2005.10.010>

García, D., Solórzano, C., Navarrete, Y., & Rojas, J. (2021). Características físicas, químicas y microbiológicas de la harina de banano morado (*Musa acuminata*) red dacca, producidos en los cantones Mocache, El Empalme y La Maná. *Ingeniería e Innovación*, 9(1), 1–12. <https://revistas.unicordoba.edu.co/index.php/rri/article/view/2418>

Gómez, J. E. G., Cárdenas, S. R., & Ruiz, F. A. S. (2023). Sistema de identificación de pacientes basado en tecnología NFC y Blockchain. *Investigación e Innovación en Ingenierías*, 11(2), 1-15. DOI: <https://doi.org/10.17081/invinno.11.2.6671>.

Gómez, J. G., Álvarez, D. S., & Ramírez, R. V. (2025, July). Sickle Cell Disease Patient Care System Using Artificial Intelligence. In *International Work-Conference on Bioinformatics and Biomedical Engineering* (pp. 230-241). Cham: Springer Nature Switzerland. [https://doi.org/10.1007/978-3-032-08452-1\\_19](https://doi.org/10.1007/978-3-032-08452-1_19).

Gómez, J. G., Riaño, V. H., & Ramirez-Gonzalez, G. (2024). A context awareness system for clinical environments. *Electronics*, 13(15), 2999. <https://doi.org/10.3390/electronics13152999>.

Gómez, J. G., Rosales, C. M., & Montaña, S. I. (2026). Sickle cell anemia prediction system in machine learning based on clinical data. *IEEE Access*. <https://doi.org/10.1109/ACCESS.2026.3674938>.

Gómez, K. Y., Caballero, L. A., & Maldonado, Y. Del C. (2021). Mejora de un proceso productivo de elaboración de pan. *Revista de Ingeniería e Innovación*.

Han, P.-L., et al. (2024). Artificial intelligence-assisted diagnosis of congenital heart disease and associated pulmonary arterial hypertension from chest radiographs: A

multi-reader multi-case study. *European Journal of Radiology*, 171, 111277.

Hernandez, I. C. F. (2020). Inteligencia Artificial aplicada a la Justicia. *Derecho y Realidad*.

Hoffman, J. I. E., & Kaplan, S. (2002, June 19). The incidence of congenital heart disease. [https://doi.org/10.1016/S0735-1097\(02\)01886-7](https://doi.org/10.1016/S0735-1097(02)01886-7)

H. Hernández Palma, D. J. Novoa, y D. Mendoza Cásseres, "Energía renovables y medidas de eficiencia energética aplicables a las instituciones prestadoras de salud en Colombia," *RCTA*, vol. 1, no. 41, pp. 123–131, may 2023, doi: 10.24054/rcta.v1i41.2557.

Instituto Nacional de Salud. (2025). Boletín epidemiológico semanal 09 de 2025 (pp. 1–42).

Italo, E. G. (2020). Efecto de inclusión de cáscara de plátano en la degradabilidad in situ de ensilaje de maíz forrajero. *Ingeniería e Innovación*, 8(1). <https://revistas.unicordoba.edu.co/index.php/rri/article/view/2327>

Jiang, X., Yu, J., Ye, J., Jia, W., Xu, W., & Shu, Q. (2023). A deep learning-based method for pediatric congenital heart disease detection with seven standard views in echocardiography. *World Journal of Pediatric Surgery*, 6(3), e000580.

K. M. Romero Villareal and M. C. M. Murgas, "Antimicrobial Potential of Secondary Metabolites: AScientometric Review," *interfaces*, vol. 7, no. 2, 2024, Available: <https://revistas.unilibre.edu.co/index.php/interfaces/article/view/12712>.

Karimi-Bidhendi, S., Arafati, A., Cheng, A. L. W., Kheradvar, A., & Jafarkhani, H. (2020). Fully automated deep learning segmentation of pediatric cardiovascular magnetic resonance of patients with complex congenital heart diseases. *Journal of Cardiovascular Magnetic Resonance*, 22(1), 80.

- Khan, K., Ullah, F., Syed, I., & Ali, H. (2024). Accurately assessing congenital heart disease using artificial intelligence. *PeerJ Computer Science*, 10, e2535.
- Lasso Cardona, L. A. ., Rincón Reyes, E. ., & Estrada Holguín, G. D. . (2020). Introducción a la evaluación de capacidades: una revisión teórica. *Revista Colombiana De Tecnologías De Avanzada (RCTA)*, 2(36), 34-43. <https://doi.org/10.24054/rcta.v2i36.18>
- Lee, Y.-S., et al. (2025). Prediction of significant congenital heart disease in infants and children using continuous wavelet transform and deep convolutional neural network with 12-lead electrocardiogram. *BMC Pediatrics*, 25(1), 324.
- Li, X., et al. (2024). A multi-task deep learning approach for real-time view classification and quality assessment of echocardiographic images. *Scientific Reports*, 14(1), 20484.
- Liu, J., Wang, H., Yang, Z., Quan, J., Liu, L., & Tian, J. (2022). Deep learning-based computer-aided heart sound analysis in children with left-to-right shunt congenital heart disease. *International Journal of Cardiology*, 348, 58–64.
- Liu, X., et al. (2020). Reporting guidelines for clinical trial reports for interventions involving artificial intelligence: The CONSORT-AI extension. *Nature Medicine*, 26(9), 1364–1374. <https://doi.org/10.1038/s41591-020-1034-x>
- Martínez Díaz, J. D., Ortega Chacón, V., & Muñoz Ronda, F. J. (2016). El diseño de preguntas clínicas en la práctica basada en la evidencia. *Modelos de formulación. Enfermería Global*, 15(3), 431.
- Miranda, O., Oyaga, R. F., Salas, A. R., Foris, Y., & Ibarquén, J. C. (2023). Impacto ambiental del botadero de residuos sólidos a cielo abierto en el corregimiento de Córdoba, departamento del Valle del Cauca. *Ingeniería e Innovación*, 11(1). <https://doi.org/10.21897/rii.3339>
- Mosquera-Perdomo, A., Salazar Galindez, J., Ramirez-Gonzalez, G., & Figueroa, C. (2023). Software for the extraction of bibliographic information registered in CvLAC and GrupLAC applied in the Department of Cauca. *Ingeniería e Innovación*, 11(2), 21. <https://doi.org/10.21897/rii.3464>
- Munn, Z., Stern, C., Aromataris, E., Lockwood, C., & Jordan, Z. (2018). What kind of systematic review should I conduct? A proposed typology and guidance for systematic reviewers in the medical and health sciences. *BMC Medical Research Methodology*, 18(1), 5.
- Nurmaini, S., et al. (2021). Deep learning-based computer-aided fetal echocardiography: Application to heart standard view segmentation for congenital heart defects detection. *Sensors*, 21(23), 8007.
- N. S. S. Carrero, N. M. A. Quintana, y L. M. S. Jaimes, "Lineamientos desde la industria 4.0 a la educación 4.0: caso tecnología IoT," *Revista Colombiana DE Tecnologías DE Avanzada (Rcta)*, vol. 1, no. 39, pp. 81-92, 2022. DOI: <https://doi.org/10.24054/rcta.v1i39.1379>.
- Nurmaini, S., et al. (2022). Deep learning for improving the effectiveness of routine prenatal screening for major congenital heart diseases. *Journal of Clinical Medicine*, 11(21), 6454.
- Nova, R., Nurmaini, S., Partan, R. U., & Putra, S. T. (2021). Automated image segmentation for cardiac septal defects based on contour region with convolutional neural networks: A preliminary study. *Informatics in Medicine Unlocked*, 24, 100601.
- Park, S., Moon, J., Eun, H., Hong, J.-H., & Lee, K. (2024). Artificial intelligence-based diagnostic support system for patent ductus arteriosus in premature infants. *Journal of Clinical Medicine*, 13(7), 2089.
- Petmezas, G., et al. (2022). State-of-the-art deep learning methods on

electrocardiogram data: Systematic review. *JMIR Medical Informatics*, 10(8), e38454.

Popay, J., et al. (2006). Guidance on the conduct of narrative synthesis in systematic reviews: A product from the ESRC Methods Programme. Peninsula Medical School, Universities of Exeter and Plymouth.

Pozza, A., Zanella, L., Castaldi, B., & Di Salvo, G. (2024). How will artificial intelligence shape the future of decision-making in congenital heart disease? *Journal of Clinical Medicine*, 13(10), 2996.

Powers, D. M. W. (2020). Evaluation: From precision, recall and F-measure to ROC, informedness, markedness and correlation. arXiv. <http://arxiv.org/abs/2010.16061>

Puche, M. B., Samper, O. M., & Martíne, R. F. (2023). Conciencia, concientización y educación ambiental: triada que se afianza en la primera infancia. *Ingeniería e Innovación*, 11, 1–16. <https://doi.org/10.21897/rii.3416>

Puchalski, M. D., et al. (2019). Guidelines for performing a comprehensive transesophageal echocardiographic examination in children and all patients with congenital heart disease: Recommendations from the American Society of Echocardiography. *Journal of the American Society of Echocardiography*, 32(2), 173–215. <https://doi.org/10.1016/j.echo.2018.08.016>

Román, G., & Gómez, J. (2017). Intervención educativa apoyada en TIC en un proceso de enseñanza aprendizaje inclusivo. *Ingeniería e Innovación*. <https://revistas.unicordoba.edu.co/index.php/rii/article/view/1728>

S. D. M. Oñate and A. F. T. Herazo, "Agrivoltaic systems: a contribution to sustainability," *interfaces*, vol. 7, no. 2, 2024, Available: <https://revistas.unilibre.edu.co/index.php/interfaces/article/view/12713>.

Santhoshi, P. M., Sajja, G. S., Dintakurthy, Y., & Bali, M. G. (2024). Detection of prenatal cardiac disease using computer vision and artificial intelligence. *Contemporary Mathematics*, 5150–5167.

Sounderajah, V., et al. (2025). The STARD-AI reporting guideline for diagnostic accuracy studies using artificial intelligence. *Nature Medicine*, 31(10), 3283–3289. <https://doi.org/10.1038/s41591-025-03953-8>

Taha, A. A., & Hanbury, A. (2015). Metrics for evaluating 3D medical image segmentation: Analysis, selection, and tool. *BMC Medical Imaging*, 15(1). <https://doi.org/10.1186/s12880-015-0068-x>

The International Society of Ultrasound in Obstetrics and Gynecology. (2013). ISUOG Practice Guidelines (updated): Sonographic screening examination of the fetal heart. *Ultrasound in Obstetrics & Gynecology*, 41(3), 348–359. <https://doi.org/10.1002/uog.12403>

Topol, E. J. (2019). High-performance medicine: The convergence of human and artificial intelligence. *Nature Publishing Group*. <https://doi.org/10.1038/s41591-018-0300-7>

Vergara Pareja, C. M., Nino Vega, J. A., y Fernandez Morales, F. H. (2022). Fortalecimiento de la lectura crítica en inglés a estudiantes de grado quinto a través de un recurso educativo digital. *Revista Colombiana de Tecnologías de Avanzada*, 2(40), 160-170. <https://doi.org/10.24054/rcta.v2i40.2370>.

Wang, J., et al. (2020). Intelligent diagnosis of heart murmurs in children with congenital heart disease. *Journal of Healthcare Engineering*, 2020, 1–9.

Wang, J., et al. (2021). Automated interpretation of congenital heart disease from multi-view

echocardiograms. *Medical Image Analysis*, 69, 101942.

Whiting, P. F., et al. (2011). QUADAS-2: A revised tool for the quality assessment of diagnostic accuracy studies. *Annals of Internal Medicine*, 155(8), 529–536.

Wu, W., He, J., & Shao, X. (2020). Incidence and mortality trend of congenital heart disease at the global, regional, and national level, 1990-2017. *Medicine*, 99(23), e20593.

Xu, J., Li, Q., Deng, L., Xiong, J., Cheng, Z., & Ye, C. (2025). Global, regional, and national epidemiology of congenital heart disease in children from 1990 to 2021. *Frontiers in Cardiovascular Medicine*, 12, 1522644.

Xu, W., et al. (2022). Automatic pediatric congenital heart disease classification based on heart sound signal. *Artificial Intelligence in Medicine*, 126, 102257. <https://doi.org/10.1016/j.artmed.2022.102257>

Ye, E., Wu, E., Tang, T., & La, X. (2025). Global, regional, and national burdens of congenital heart anomalies from 1990 to 2021, and projections to 2050. *Frontiers in Pediatrics*, 13, 1601620.

Zimmerman, M. S., et al. (2020). Global, regional, and national burden of congenital heart disease, 1990–2017: A systematic analysis for the Global Burden of Disease Study 2017. *The Lancet Child & Adolescent Health*, 4(3), 185–200. [https://doi.org/10.1016/S2352-4642\(19\)30402-X](https://doi.org/10.1016/S2352-4642(19)30402-X)

Zou, K. H., et al. (2004). Statistical validation of image segmentation quality based on a spatial overlap index. *Scientific Reports*. <http://www.slicer.org>