

Inteligencia Artificial (IA) en el triaje de atención primaria: Una revisión sobre la precisión diagnóstica

Artificial Intelligence (AI) in primary care} triage: A review on diagnostic accuracy

Danny Ariel Rojas Aimacaña

Ingeniero en Biotecnología de los Recursos Naturales.
Magíster en Dirección de Operaciones y Seguridad Industrial
Docente Universidad Metropolitana
drojas@umet.edu.ec
<https://orcid.org/0009-0005-4668-4510>

Julissa Alexandra Sánchez Yánez

Licenciada en Ciencias de la Enfermería. Magíster en Salud Pública
Docente en la Universidad Metropolitana
jasanchez@umet.edu.ec
<https://orcid.org/0000-0001-9823-0530>

María Valeria García Flores

Licenciada en Ciencias de la Enfermería.
Magíster en Salud Pública
Docente en la Universidad Metropolitana
mvgarcia@umet.edu.ec
<https://orcid.org/0009-0006-3040-6927>

Jasnaya Isabel Juiña Caluña

Licenciada en Imagenología y Radiología
Docente en la Universidad Metropolitana
jjuina@umet.edu.ec
<https://orcid.org/0009-0000-5785-9543>

Resumen

La saturación estructural en la atención primaria y los servicios de urgencias incrementa la variabilidad clínica y los errores médicos, afectando de forma directa la oportunidad y la seguridad del paciente. Frente a esto, la Inteligencia



Imaginario Social
Entidad editora
REDICME (reg-red-18-0061)

e-ISSN: 2737-6362
julio-diciembre 2026 Vol. 9-3-2026
<http://revista-imaginariosocial.com/index.php/es/index>

Recepción: 20 de mayo de 2026
Aceptación: 16 de junio de 2026

146-165

Atribución/Reconocimiento-NoComercial- CompartirIgual 4.0 Licencia Pública Internacional — CC
BY-NC-SA 4.0
<https://creativecommons.org/licenses/by-nc-sa/4.0/legalcode.es>

Artificial (IA) clínica surge como un motor de transformación digital capaz de optimizar la gestión de la demanda asistencial. Este artículo de revisión evalúa la precisión diagnóstica y la efectividad de las herramientas de IA aplicadas al triaje y cribado clínico. Para ello, se realizó una revisión integrativa de la literatura donde se seleccionaron y analizaron sistemáticamente 14 documentos científicos indexados publicados entre 2020 y 2025.

Los resultados evidencian que los modelos de aprendizaje profundo (*Deep Learning*) alcanzan un rendimiento global elevado, con sensibilidades del 91% al 100% y áreas bajo la curva de hasta 0.99 en ecocardiografía y radiografías, logrando mitigar entre el 60% y 70% de los errores perceptivos humanos condicionados por la fatiga. Asimismo, las arquitecturas de aprendizaje automático y procesamiento de lenguaje natural agilizan los flujos prehospitalarios de triaje a tiempos inferiores a los 2 minutos. Se concluye que la IA es un potente filtro predictivo que reduce reingresos evitables y robustece la consistencia médica. Su adopción exitosa requiere validación clínica local, interoperabilidad de infraestructura, capacitación continua y una estricta gobernanza ética bajo supervisión humana definitiva.

Palabras clave: Inteligencia artificial, triaje, atención primaria, precisión diagnóstica, seguridad del paciente

Abstract

Structural saturation in primary care and emergency departments increases clinical variability and medical errors, directly impacting timeliness and patient safety. In response, clinical Artificial Intelligence (AI) emerges as a driver of digital transformation capable of optimizing healthcare demand management. This review article evaluates the diagnostic accuracy and effectiveness of AI tools applied to clinical triage and screening. To achieve this, an integrative literature review was conducted, systematically selecting and analyzing 14 indexed scientific documents published between 2020 and 2025.

The results show that deep learning models achieve high overall performance, demonstrating sensitivities of 91% to 100% and areas under the curve (AUC) of up to 0.99 in echocardiography and radiographs, successfully mitigating between 60% and 70% of human perceptual errors caused by fatigue. Furthermore, machine learning

and natural language processing architectures streamline pre-hospital triage workflows to times under 2 minutes. It is concluded that AI serves as a powerful predictive filter that reduces avoidable readmissions and strengthens clinical consistency. Its successful adoption requires local clinical validation, infrastructural interoperability, continuous training, and strict ethical governance under definitive human supervision.

Keywords: Artificial intelligence, Triage,

Introducción

El primer nivel de atención médica constituye el eje estructural de los sistemas sanitarios modernos debido a su capacidad intrínseca para ofrecer un cuidado integral, coordinado y centrado de forma directa en las necesidades de las personas (Leones Pico, 2023; Valdés Martínez & Barragán Cutiva, 2025). Sin embargo, en el panorama contemporáneo de la salud global, la atención primaria enfrenta una crisis de carácter estructural que pone en riesgo tanto la calidad como la oportunidad asistencial (Leones Pico, 2023).

Este escenario crítico se encuentra fuertemente condicionado por factores complejos como la sobrecarga de la demanda, la variabilidad no controlada en la toma de decisiones clínicas, los prolongados tiempos de espera en salas de urgencias y un flujo recurrente de consultas por patologías no urgentes que terminan congestionando innecesariamente las redes de atención (Leones Pico, 2023; Valdés Martínez & Barragán Cutiva, 2025).

En los servicios de urgencias hospitalarios y extrahospitalarios, esta presión asistencial y de tiempo obliga a los profesionales a laborar en entornos de alta tensión organizativa y fatiga perceptual, lo que incrementa de manera exponencial la vulnerabilidad del sistema ante la ocurrencia de omisiones o errores diagnósticos (Garrido-Bueno et al., 2026; Herrera Pacheco & Terán Pino, 2024).

Bajo esta perspectiva, los errores en la fase de diagnóstico clínico representan uno de los mayores desafíos para la seguridad de los pacientes y para la eficiencia financiera de las instituciones prestadoras de salud (Herrera Pacheco & Terán Pino, 2024; Organización Mundial de la Salud [OMS], como se citó en Ardila Romero & Espinosa Muñoz, 2025). La literatura científica reporta de forma persistente que entre el 5% y

el 20% de las interacciones cotidianas entre médicos y pacientes están expuestas a algún tipo de fallo diagnóstico, siendo los errores de percepción visual y sublectura en el análisis de imágenes los más prevalentes en los entornos de urgencia (Leones Pico, 2023; Ardila Romero & Espinosa Muñoz, 2025).

Con el propósito de mitigar esta problemática y optimizar la canalización de la demanda asistencial, los sistemas sanitarios han adoptado de forma obligatoria protocolos manuales de clasificación y selección de pacientes, conocidos técnicamente como sistemas de triaje, los cuales estratifican la prioridad clínica a través de niveles jerárquicos de gravedad fisiológica (Herrera Pacheco & Terán Pino, 2024; Valdés Martínez & Barragán Cutiva, 2025). No obstante, la implementación efectiva de estos esquemas se ve seriamente obstaculizada por su alta dependencia de procesos manuales, la variabilidad conceptual de los evaluadores humanos y la escasez de herramientas digitales integradas que actúen de manera estandarizada y consistente en la etapa prehospitalaria (Valdés Martínez & Barragán Cutiva, 2025).

Frente a estas limitaciones estructurales e instrumentales del factor humano, la salud digital y la progresiva integración de la Inteligencia Artificial (IA) clínica emergen como los principales motores de innovación y resiliencia organizativa en el sector sanitario (Garrido-Bueno et al., 2026; Leones Pico, 2023). A través de la aplicación convergente de algoritmos avanzados de aprendizaje automático (*Machine Learning*) y modelos jerárquicos de aprendizaje profundo (*Deep Learning*), la tecnología médica actual cuenta con la capacidad de procesar masivos volúmenes de datos biomédicos y paraclínicos en tiempo real (Garrido-Bueno et al., 2026; Herrera Pacheco & Terán Pino, 2024).

Estas herramientas digitales están diseñadas para identificar patrones clínicos complejos y sutiles que suelen pasar desapercibidos bajo la lógica humana tradicional, actuando así como una capa transversal de soporte predictivo y filtro prehospitalario para la toma de decisiones críticas (Leones Pico, 2023; Valdés Martínez & Barragán Cutiva, 2025; Ardila Romero & Espinosa Muñoz, 2025). En consecuencia, la literatura contemporánea evidencia resultados prometedores del uso de la IA en la reducción de falsos negativos, la priorización automatizada de estudios críticos, y la disminución del tiempo transcurrido entre el ingreso del usuario y el establecimiento de una conducta

médica certera (Castro-Delgado & Pardo Ríos, 2024; Ardila Romero & Espinosa Muñoz, 2025; Villa Feijoó & Zapata Velasco, 2025).

Pese a los evidentes beneficios de precisión y eficiencia que los algoritmos predictivos aportan a los flujos asistenciales, su traslación y adopción definitiva en la atención primaria no es automática y enfrenta rigurosos desafíos científicos, éticos y formativos (Leones Pico, 2023).

El rendimiento óptimo de un modelo de IA depende de manera crítica del acceso a ecosistemas de datos clínicos altamente estructurados, fiables e interoperables; por lo tanto, el entrenamiento con registros sesgados o incompletos arriesga la equidad en salud, reproduciendo desigualdades territoriales y socioeconómicas en poblaciones vulnerables (Garrido-Bueno et al., 2026; Leones Pico, 2023). Asimismo, persisten debates profundos sobre la falta de explicabilidad algorítmica de los modelos de "caja negra" y la definición de responsabilidades ético-legales en caso de incurrir en fallas diagnósticas no supervisadas (Leones Pico, 2023; Villa Feijoó & Zapata Velasco, 2025).

Por consiguiente, la comunidad científica concuerda en que la tecnología no debe desplazar las dimensiones esenciales del cuidado humano o la autonomía del profesional (Garrido-Bueno et al., 2026; Leones Pico, 2023). En su lugar, el despliegue de la IA debe orientarse hacia un modelo híbrido y complementario de toma de decisiones asistida que combine de manera segura la capacidad analítica computacional con el juicio clínico y el sentido ético del ser humano (Castro-Delgado & Pardo Ríos, 2024; Leones Pico, 2023; Ardila Romero & Espinosa Muñoz, 2025).

En este contexto de transformación digital e innovación en salud, se justifica la realización de esta revisión bibliográfica de la literatura científica actual (Valdés Martínez & Barragán Cutiva, 2025).

Por tanto, el presente artículo académico se propone evaluar el impacto, las métricas de rendimiento y la efectividad de las herramientas basadas en inteligencia artificial aplicadas al triaje de atención primaria, analizando de manera integradora su nivel de precisión diagnóstica, sus limitaciones metodológicas, y las recomendaciones estratégicas necesarias para garantizar un despliegue seguro, equitativo y de alto valor público dentro de los servicios sanitarios contemporáneos (Leones Pico, 2023; Flórez Pacheco et al., 2026; Villa Feijoó & Zapata Velasco, 2025).

Metodología

El presente estudio se desarrolló bajo un enfoque metodológico de tipo descriptivo y transversal, fundamentado en una estrategia de revisión integrativa y documental de la literatura científica contemporánea. Este diseño de investigación cualitativa y analítica permite recopilar, evaluar críticamente y sintetizar la evidencia empírica disponible en bases de datos indexadas sobre el uso de tecnologías inteligentes en los procesos asistenciales de la salud digital.

La estrategia de búsqueda y recolección de información se realizó en las bases de datos bibliográficas de alto impacto Scopus, PubMed y Google Scholar. Para la delimitación precisa del corpus, se utilizaron operadores booleanos (*AND* y *OR*) combinando palabras clave y descriptores controlados (MeSH y DeCS), tales como: "*Artificial Intelligence*", "*Machine Learning*", "*Deep Learning*", "*Triage*", "*Primary Health Care*" y "*Diagnostic Accuracy*".

La búsqueda se limitó a investigaciones originales publicadas en el período comprendido entre los años 2020 y 2025. Los criterios de inclusión exigieron artículos originales de investigación empírica o validaciones clínicas, enfocados en evaluar la efectividad diagnóstica de la IA en la clasificación de riesgo en urgencias o atención primaria, disponibles en texto completo y redactados en idioma español o inglés. Se excluyeron notas editoriales, cartas, estudios duplicados o aquellos que no informaran métricas cuantitativas mínimas de sensibilidad, especificidad o área bajo la curva (AUC). Tras aplicar rigurosamente estos criterios de elegibilidad, se seleccionaron y analizaron un total de 14 documentos científicos.

Para el proceso de extracción de datos, la información se codificó sistemáticamente en matrices guías de lectura de elaboración propia. Estas herramientas permitieron tabular variables críticas como autor, año, país, diseño, tamaño de muestra, modalidad diagnóstica evaluada (ecocardiografía, electrocardiografía, fonocardiografía o radiografía de tórax) y tipo de algoritmo utilizado. Finalmente, los datos consolidados se analizaron mediante una síntesis narrativa integradora para identificar patrones, brechas técnicas, factores de éxito y limitaciones ético-legales en la práctica médica contemporánea.

Resultados

Caracterización de la literatura seleccionada

A partir de la estrategia de búsqueda y la aplicación rigurosa de los criterios de elegibilidad metodológica, se seleccionaron y analizaron de forma completa un total de 14 documentos científicos publicados en el período reciente comprendido entre los años 2020 y 2025. El análisis geográfico de la producción científica identificó un marcado liderazgo de la región Asia-Pacífico: el 57.14% () de las investigaciones provienen de China, seguidas por estudios desarrollados en Indonesia, Taiwán y la República de Corea. El resto del corpus documental se distribuyó entre entornos clínicos de los Estados Unidos y los Países Bajos.

En lo relativo al diseño metodológico, el 50% del total de los trabajos analizados correspondieron a estudios retrospectivos de centro único o multicéntricos, mientras que el 50% restante se distribuyó entre estudios de tipo prospectivo, observacionales transversales, y modelos de desarrollo con validación diagnóstica. Las características esenciales de cada una de las investigaciones se detallan de forma consolidada en la tabla 1.

Tabla 1: Matriz integrada de métricas de precisión, aplicaciones y hallazgos clínicos de los modelos de IA en el triaje y diagnóstico.

ID	Autor (Año)	País / Entorno	Diseño del Estudio	Población (/ Muestra)	Tipo de IA / Algoritmo	Arquitectura / Software
01	Nurmaini et al. (2021)	Indonesia	Observacional analítico, transversal (hospital único)	50 pacientes (1149 imágenes)	Deep Learning	Mask R-CNN (ResNet50, multi-task)
02	Athalye et al. (2024)	Países Bajos	Retrospectivo (entorno comunitario)	108 estudios ultrasonido	Ensamble Deep Learning	Detección de vista + decisión + agregación
03	Jiang et al. (2023)	China	Retrospectivo , single-center	1376 pacientes (14838 imágenes)	Deep Learning	ResNet50 (Transfer Learning)
04	Nurmaini et al. (2022)	Indonesia	Diagnóstico (tamizaje prenatal US)	76 pacientes (1129 frames)	Deep Learning + XAI	DenseNet201 + Inteligencia artificial explicable
05	Park et al. (2024)	Rep. de Corea	Retrospectivo (EHR en NICU)	409 prematuros (4726 muestras)	Machine Learning	Random Forest

06	Wang et al. (2020)	China	Registro hospitalario (centro PCG)	86 registros fonocardiograma	Redes Neuronales Artificiales	ANN (Levenberg - Marquardt, 3 capas)
07	Liu et al. (2022)	China	Monocéntrico (hospital pediátrico)	884 grabaciones fonocardiograma	Deep Learning	RCRnet
08	Chen et al. (2024)	China	Retrospectivo multicéntrico	93,127 registros ECG	Deep Learning + Atención	CHDdECG (Conv1D + Transformer)
09	Lee et al. (2025)	Taiwán	Retrospectivo, single-center	1,035 registros ECG	Transformada + Deep Learning	CWT + CNN (ResNet-18)
10	Cheng et al. (2024)	China	Validación clínica cruzada	1,932 (Ecocardiograma TTE)	Deep Learning (Fusión)	ResNet18 + FCNN
11	Wang et al. (2021)	China	Dataset hospitalario independiente	1,308 sujetos (Ecocardiograma)	Deep Learning	CNN multicanal (agregación temporal)
12	Karimi-Bidhendi (2020)	USA	Retrospectivo (CMR pediátrica)	64 estudios (Resonancia CMR)	Deep Learning (Segmentación)	FCN / FCN-SAD (+ DCGAN)
13	Han et al. (2024)	China	Retrospectivo + MRMC	3255 radiografías de tórax	Deep Learning	ResNet18 (Pretrained)
14	Xu et al. (2022)	China	Desarrollo y evaluación	941 señales PCG	Machine Learning (Voto)	Segmentación PCG + 84 features + voting

Rendimiento clínico y precisión diagnóstica de los modelos de IA

El análisis integrativo de las métricas de rendimiento global evidenció que el uso de soluciones informáticas inteligentes alcanza una efectividad diagnóstica notablemente alta. Los rangos globales calculados a partir de los estudios se situaron entre un 73.9% y un 100% en exactitud (*accuracy*), un 71% y un 100% en sensibilidad, y un 71.5% y un 100% en especificidad operativa.

Las técnicas de Deep Learning demostraron un claro dominio y efectividad clínica en el análisis de imágenes y videos multi-vista en ecocardiografía, alcanzando de manera consistente sensibilidades elevadas (91.0% - 100.0%) y áreas bajo la curva (AUC) que oscilan entre 0.910 y 0.990. Las modalidades orientadas a señales continuas, tales como la electrocardiografía (ECG) y la fonocardiografía (PCG), registraron un comportamiento óptimo para procesos de triaje de gran volumen y cribado masivo en

la atención primaria. Las métricas cuantitativas y los comparadores clínicos de cada investigación se detallan de forma pormenorizada en la Tabla 2.

Tabla 2: Matriz integrada de métricas de precisión, aplicaciones y hallazgos clínicos de los modelos de IA en el triaje y diagnóstico.

ID	Modalidad / Datos	Patología o Caso de Uso Clínico	Algoritmo / Arquitectura	Métricas de Rendimiento / Impacto	Hallazgos Clínicos y Aportes a la Calidad
01	Ecocardiografía	Cardiopatías prenatales y septales (ASD/VSD)	DenseNet201 / ResNet18 + FCNN	Sensibilidad: 91% - 100% Especificidad: 78% - 100% AUC: 0.910 - 0.990	Eleva significativamente la tasa de detección en entornos comunitarios frente al tamizaje manual tradicional.
02	Electrocardiografía (ECG)	Detección masiva de CHD en población pediátrica	CHDdECG (Conv1D + Transformer con atención)	Sensibilidad: 77% - 80% Especificidad: 88.1% - 93.7% AUC: 0.915	Integra conceptos clínicos humanos; supera el desempeño de cardiólogos en el triaje de grandes cohortes.
03	Radiografía de Tórax (CXR)	Diagnóstico asistido de CHD e Hipertensión Pulmonar	ResNet18 (Preentrenada)	Sensibilidad: 97% (CHD) / 63.2% (PAH) Especificidad: 98.2% (CHD)	Funciona como una segunda lectura rápida que eleva el rendimiento de los radiólogos jóvenes en entornos saturados.
04	Fonocardiografía (PCG)	Clasificación e interpretación de soplos cardíacos	RCRnet / Algoritmos de votación (RF + Adaboost)	Exactitud (<i>Accuracy</i>): 94% - 99.4% Sensibilidad: 93.2% - 100%	Extrae sutiles características físicas de la señal de audio, superando la precisión de la auscultación manual experta.
05	Síntomas y Signos Clínicos	<i>SmartTriage</i> : Priorización prehospitalaria en urgencias	Prototipo PWA inspirado en <i>Machine Learning</i> (Lasso, Random Forest)	Tiempo objetivo de triaje: ≤ 2 min.	Canaliza la demanda asistencial prehospitalaria y orienta al paciente mediante geolocalización

				Clasificación alineada con Res. 5596/2015	hacia redes de IPS.
06	Datos Clínicos Estructurados	<i>Penta estrategia:</i> Reducción de reingresos en urgencias	Modelos de predicción y gestión basados en <i>Machine/Deep Learning</i>	Meta de reducción de reingresos evitables: < 10% Precisión esperada: > 90%	Estructura un ciclo de 5 fases (recolección, ML, triaje, asistencia y evaluación) para optimizar recursos financieros.
07	Imágenes Radiológicas de Urgencia	Reducción de errores en urgencias de baja complejidad	Sistemas de IA integrados a redes PACS/RIS	Mitigación del 60%-70% de errores perceptivos (sublecturas)	Actúa como un soporte de alerta automatizada ante la fatiga del personal, reduciendo incidentes con daño grave.
08	Registros Médicos y Síntomas	IA clínica y calidad asistencial en el primer nivel	Sistemas de Apoyo a la Decisión Clínica (SADC)	Correlación positiva significativa con seguridad y oportunidad (\$p < 0.001\$)	Fortalece de forma directa la consistencia de la práctica médica y la seguridad diagnóstica ante información incompleta.
09	Historias Clínicas Electrónicas	<i>Epic Sepsis</i> y aplicación <i>KATE</i> en triaje de urgencias	Modelos de aprendizaje automático y refuerzo de gradiente (XGBoost)	Precisión de triaje <i>KATE</i> : 27% mayor que el promedio de enfermería	Demuestra efectividad en la priorización de flujos y detección precoz de riesgos críticos a partir de datos estructurados.
10	Interacción Asistencial / Audio	Aplicaciones móviles, Chatbots y sistema <i>Corti</i>	Procesamiento de Lenguaje Natural (NLP) e IA Generativa	Reconocimiento automático del habla y análisis de gravedad	Identifica eventos críticos (como paros cardíacos en llamadas) de forma más ágil que los despachadores humanos.

Análisis por modalidad diagnóstica y tecnológica

Hallazgos en ecocardiografía y análisis multivista

La ecocardiografía se consolidó como la modalidad con mayor volumen de estudios y el rendimiento analítico más robusto dentro de la literatura seleccionada (Flórez Pacheco et al., 2026). Los algoritmos basados en *Deep Learning* aplicados a esta área demostraron una alta capacidad para resolver las limitaciones de la lectura manual,

las cuales se caracterizan por una de las mayores dependencias del operador y variabilidad interobservador (Flórez Pacheco et al., 2026). Las investigaciones prenatales evidenciaron que la IA es capaz de segmentar automáticamente las estructuras de vistas cardíacas estándar con precisiones intra-paciente del 100% (Flórez Pacheco et al., 2026).

En validaciones retrospectivas y comunitarias, los modelos de ensamble demostraron una sensibilidad del 91% en la detección de anomalías estructurales severas, superando las tasas de detección del tamizaje clínico comunitario inicial (Flórez Pacheco et al., 2026). En el entorno pediátrico, las arquitecturas ResNet50 permitieron la interpretación de videos y secuencias dinámicas de imágenes (*key-frames*), logrando un área bajo la curva (AUC) de 0.910 a 0.990 (Flórez Pacheco et al., 2026). Estos sistemas multi-canal imitan la lógica de exploración médica al integrar datos de múltiples ventanas acústicas, facilitando el cribado binario y la identificación oportuna de defectos septales (Flórez Pacheco et al., 2026).

Hallazgos en Electrocardiografía (ECG) de alta escala

El procesamiento informático de registros electrocardiográficos se posicionó como una alternativa tecnológica fundamental para el triaje y cribado masivo en la atención primaria debido a la alta disponibilidad y bajo costo relativo de la prueba (Flórez Pacheco et al., 2026). Los estudios que incorporaron grandes bases de datos estructuradas (destacando validaciones multicéntricas con más de 93,000 trazados) reportaron el desarrollo de modelos que integran características extraídas por *Deep Learning* con conceptos clínicos humanos (Flórez Pacheco et al., 2026).

Estos modelos lograron un AUC de 0.915 en la detección binaria de cardiopatías complejas, demostrando una alta generalización en centros externos (Flórez Pacheco et al., 2026). En menores de 5 años, el uso clínico de la transformada continua de Wavelet (CWT) combinada con redes neuronales ResNet-18 permitió clasificar anomalías hemodinámicamente significativas con una exactitud del 73.9%, sirviendo como un potente filtro predictivo prehospitalario previo a la confirmación ecográfica (Flórez Pacheco et al., 2026).

Aplicaciones en fonocardiografía (PCG) y señales de audio

El análisis computacional de soplos cardíacos mediante el registro de señales acústicas registró una efectividad diagnóstica elevada para el tamizaje no invasivo (Flórez Pacheco et al., 2026). Los resultados indicaron que la aplicación de Redes Neuronales Artificiales (ANN) y modelos basados en la arquitectura RCRnet alcanzan exactitudes operativas de entre el 93% y el 99.4%, con sensibilidades de hasta el 100% en la detección de soplos asociados a cortocircuitos cardíacos (Flórez Pacheco et al., 2026). Los modelos que emplearon la extracción automatizada de características (identificando hasta 84 descriptores de la señal de audio) y algoritmos de votación como *Random Forest* y *Adaboost* demostraron una precisión del 95.3%, logrando diferenciar soplos patológicos de inocentes (Flórez Pacheco et al., 2026). Este rendimiento técnico supera la sensibilidad de la auscultación manual realizada por médicos generales, reduciendo la variabilidad diagnóstica (Flórez Pacheco et al., 2026).

Radiografía de tórax y segmentación anatómica avanzada

En entornos de baja complejidad y alta demanda asistencial, la radiografía de tórax frontal (CXR) asistida por algoritmos preentrenados de *Deep Learning* emergió como un recurso estratégico de segunda lectura ágil (Ardila Romero & Espinosa Muñoz, 2025; Flórez Pacheco et al., 2026). Los modelos entrenados con arquitecturas ResNet18 demostraron una sensibilidad del 97% y una especificidad del 98.2% en la identificación de cardiopatías congénitas, alcanzando un AUC de 0.948 (Flórez Pacheco et al., 2026). Asimismo, demostraron capacidad para clasificar la hipertensión arterial pulmonar asociada con un AUC de 0.778, mejorando significativamente la precisión diagnóstica de los radiólogos jóvenes asistidos por el algoritmo (Flórez Pacheco et al., 2026).

En lo que respecta a la resonancia magnética cardiovascular (CMR), el uso de Redes Totalmente Convolucionales (FCN) permitió la segmentación anatómica ventricular automatizada en cardiopatías complejas, alcanzando coeficientes Dice superiores a 0.91 y superando a las herramientas de software comerciales convencionales (Flórez Pacheco et al., 2026).

Impacto en los atributos de calidad, flujos de triaje y errores médicos

Optimización del triaje prehospitalario y gestión de la demanda

La integración de las soluciones analizadas evidencia un impacto directo en los atributos de oportunidad y eficiencia del sistema de salud (Herrera Pacheco & Terán Pino, 2024; Leones Pico, 2023). En el análisis del prototipo *SmartTriage*, concebido bajo una arquitectura de Aplicación Web Progresiva (PWA), se demostró la factibilidad de registrar síntomas y signos de alarma en un tiempo corto con un flujo claro y lineal (Valdés Martínez & Barragán Cutiva, 2026). Esta agilidad operativa se complementa con módulos de geolocalización que canalizan la demanda de atenciones orientando al paciente hacia centros médicos cercanos (Valdés Martínez & Barragán Cutiva, 2026).

A nivel intrahospitalario, modelos de aprendizaje automático basados en refuerzo de gradiente (como la aplicación *KATE*) registraron una precisión en el triaje de urgencias un 27% mayor en comparación con el promedio de enfermería (Castro-Delgado & Pardo Ríos, 2024). Asimismo, en la recepción de llamadas de emergencia, el uso de procesamiento de lenguaje natural (NLP) a través de sistemas como *Corti* demostró ser más veloz y preciso en la identificación de eventos críticos (como paros cardíacos extrahospitalarios) que los médicos despachadores (Castro-Delgado & Pardo Ríos, 2024).

Reducción de reingresos y mitigación del error humano

Los hallazgos documentales y las encuestas aplicadas al talento humano en salud confirman que entre el 60% y el 70% de los errores diagnósticos cometidos en radiología de urgencias corresponden a fallas perceptivas (*sublecturas* u omisiones visuales provocadas por el cansancio y la sobrecarga laboral) (Ardila Romero & Espinosa Muñoz, 2025). Al evaluar la percepción y confiabilidad del personal médico, el 75% de los profesionales de la salud reconoció que la incorporación de alertas automatizadas e IA integrada a los sistemas PACS/RIS institucionales actúa como una herramienta de apoyo que reduce errores y mejora la seguridad del paciente (Ardila Romero & Espinosa Muñoz, 2025).

Por otra parte, la formulación de modelos predictivos y de gestión clínica estructurados en fases de mejora continua (como la *Penta estrategia*) demostró la viabilidad de analizar datos en tiempo real para anticipar riesgos de complicaciones,

estableciendo planes orientados a disminuir de manera considerable las tasas de reingreso hospitalario (Herrera Pacheco & Terán Pino, 2024). En este sentido, la correlación positiva registrada entre el uso de la IA clínica y las dimensiones de seguridad, oportunidad y apoyo a la toma de decisiones ($p < .001$) demuestra que estas tecnologías ofrecen un soporte directo que fortalece la consistencia de la práctica médica y reduce de forma tangible la ocurrencia de incidentes en entornos asistenciales tensionados (Leones Pico, 2023; Ardila Romero & Espinosa Muñoz, 2025).

Discusión

Los hallazgos de esta revisión demuestran que la integración de la Inteligencia Artificial (IA) en los procesos de triaje y soporte de atención primaria alcanza una precisión diagnóstica elevada, con exactitudes globales que oscilan entre el 73.9% y el 100%. El marcado predominio de arquitecturas de aprendizaje profundo (*Deep Learning*) en la evaluación de ecocardiografías, radiografías y trazados electrocardiográficos confirma que los modelos neuronales son altamente eficientes para corregir los errores de tipo perceptivo (sublecturas u omisiones visuales). Estos fallos representan entre el 60% y el 70% de los incidentes en los servicios de urgencias y suelen verse exacerbados por factores sistémicos críticos como la fatiga del personal, turnos extendidos y la sobrecarga laboral (Ardila Romero & Espinosa Muñoz, 2025). Al actuar como un "segundo lector" o filtro automatizado de alertas rápidas, la IA no solo optimiza la consistencia de la práctica médica, sino que mitiga de manera directa los falsos negativos que ponen en riesgo la seguridad del paciente (Schleidgen et al., como se citó en Ardila Romero & Espinosa Muñoz, 2025; Leones Pico, 2023).

A pesar de las elevadas métricas operativas registradas —destacando sensibilidades de hasta el 100% en análisis fonocardiográficos y áreas bajo la curva (AUC) de 0.99 en cribados ecocardiográficos multi-vista—, la evidencia científica seleccionada expone brechas metodológicas importantes que limitan su generalización (Flórez Pacheco et al., 2026). Existe una concentración geográfica de la literatura en la región de Asia-Pacífico y un sesgo generalizado hacia diseños de investigación retrospectivos y monocéntricos (Flórez Pacheco et al., 2026). La escasez de validaciones prospectivas externas en flujos reales de trabajo genera desconfianza legítima entre el personal

asistencial, quienes perciben los algoritmos basados en redes profundas como "cajas negras" carentes de explicabilidad (Ardila Romero & Espinosa Muñoz, 2025; Villa Feijoó & Zapata Velasco, 2025). Por este motivo, la comunidad científica coincide en rechazar la automatización no supervisada; el modelo óptimo debe ser híbrido y complementario, combinando la velocidad analítica del software con el juicio clínico contextual, la empatía y la responsabilidad del profesional humano (Castro-Delgado & Pardo Ríos, 2024; Leones Pico, 2023; Ardila Romero & Espinosa Muñoz, 2025).

En el plano de la gestión y la salud digital, la viabilidad de estas herramientas se encuentra supeditada a severas restricciones de infraestructura y capacitación (Valdés Martínez & Barragán Cutiva, 2026; Ardila Romero & Espinosa Muñoz, 2025). Los profesionales perciben que la disponibilidad de hardware, conectividad y redes estables es parcial o deficiente en los centros de atención de baja complejidad, lo que restringe la interoperabilidad con los sistemas de información hospitalaria (HIS/RIS/PACS) y compromete la oportunidad de la atención (Khalifa & Albadawy, como se citó en Ardila Romero & Espinosa Muñoz, 2025; Leones Pico, 2023; Valdés Martínez & Barragán Cutiva, 2026). Asimismo, la brecha educativa es alarmante: más del 62% del talento humano carece de formación específica en tecnologías de IA, y la oferta académica actual es escasa o limitada por los costos y la carga laboral (Ardila Romero & Espinosa Muñoz, 2025). Para garantizar un uso clínico seguro y efectivo que no genere fatiga por exceso de alertas, las instituciones de salud deben diseñar programas de capacitación escalonados y certificados antes de desplegar estas soluciones (Wenderott et al., como se citó en Ardila Romero & Espinosa Muñoz, 2025; Leones Pico, 2023).

Finalmente, la dimensión ética y normativa de la IA clínica exige un análisis riguroso en el primer nivel de atención (Leones Pico, 2023). El entrenamiento de modelos con bases de datos históricas e incompletas introduce sesgos que pueden amplificar las inequidades asistenciales preexistentes en poblaciones vulnerables (Garrido-Bueno et al., 2026; Leones Pico, 2023). Además, la ausencia de normativas globalmente unificadas que regulen la responsabilidad médica legal ante un error de diagnóstico asistido genera incertidumbre jurídica para las instituciones (Villa Feijoó & Zapata Velasco, 2025). En consecuencia, soluciones tecnológicas de triaje prehospitalario (como *SmartTriage*) o modelos estructurados de control de reingresos (como la *Penta*

estrategia) deben incorporar desde su diseño arquitectónico estrictos protocolos de protección de datos personales (*Habeas Data*), anonimización y comités de gobernanza ética (Herrera Pacheco & Terán Pino, 2024; Valdés Martínez & Barragán Cutiva, 2026). Solo mediante un marco regulatorio claro y una adopción gradual, la IA se consolidará como un instrumento de gestión de la calidad capaz de aportar valor público sostenible a la atención primaria (Leones Pico, 2023; Villa Feijoó & Zapata Velasco, 2025).

Conclusiones

La presente revisión de la literatura evidencia de manera contundente que la integración de la Inteligencia Artificial (IA) en los procesos de triaje y soporte asistencial de la atención primaria posee un potencial transformador para optimizar la asignación de recursos, reducir significativamente los tiempos de espera y mitigar los errores de naturaleza perceptiva derivados de la sobrecarga laboral y el cansancio del factor humano.

Las métricas cuantitativas consolidadas a partir de los 14 documentos analizados confirman que los modelos basados en aprendizaje profundo (*Deep Learning*) alcanzan niveles de sensibilidad y especificidad sobresalientes, especialmente en la interpretación de ecocardiografías, trazados electrocardiográficos y radiografías de tórax, consolidándose como filtros predictivos altamente confiables.

Sin embargo, los resultados también demuestran que la innovación tecnológica por sí sola es insuficiente para transformar la calidad de los servicios de salud de manera automática. La efectividad de estas herramientas inteligentes en el ámbito clínico depende críticamente de su acoplamiento con un rediseño de procesos organizacionales, de la validación local de los algoritmos con datos representativos de cada entorno y del establecimiento de marcos rigurosos de gobernanza, ética y ciberseguridad que garanticen la equidad y la transparencia operativa. En este sentido, la comunidad científica concuerda de forma unánime en que la IA debe concebirse como un instrumento complementario de segunda lectura rápida y soporte a la decisión, manteniendo siempre el veredicto diagnóstico final bajo la supervisión y juicio del profesional clínico humano.

Finalmente, de cara a una implementación sostenible en servicios de salud de baja complejidad en entornos como el latinoamericano, resulta imperativo superar barreras estructurales de infraestructura e interoperabilidad técnica, así como mitigar la alarmante brecha formativa del personal asistencial. Las gerencias y comités de calidad institucional deben guiar la adopción tecnológica mediante un despliegue progresivo por fases, priorizando aplicaciones de alta madurez algorítmica y gran volumen (como la radiografía de tórax o trauma), y promoviendo programas de educación y certificación continua que aseguren la idoneidad profesional. Solo bajo una planificación gerencial que sitúe la seguridad del paciente y la humanización como ejes rectores, la salud digital podrá responder con éxito a los desafíos contemporáneos de la atención primaria.

Referencias Bibliográficas

- Ardila Romero, S., & Espinosa Muñoz, L. J. (2025). *Estrategia para reducir los errores diagnósticos en radiología en servicios de urgencias de baja complejidad mediante el uso de la inteligencia artificial* (Trabajo de grado, Universidad El Bosque). Repositorio Institucional Universidad El Bosque. <https://repositorio.unbosque.edu.co/>
- 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. <https://doi.org/10.1002/uog.27514>
- Castro-Delgado, R., & Pardo Ríos, M. (2024). La inteligencia artificial y los servicios de urgencias y emergencias: debemos dar un paso adelante. *Emergencias*, 36, 145-147. <https://ria.asturias.es/RIA/bitstream/123456789/14824/1/Emergencias%20inteligencia%20artificial.pdf>
- Chen, J., et al. (2024). Congenital heart disease detection by pediatric electrocardiogram based deep learning integrated with human concepts. *Nature Communications*, 15(1), 976. <https://doi.org/10.1038/s41467-024-45123-x>
- 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. *Cardiovascular Research*, 7, 319. <https://doi.org/10.1093/cvr/cvae042>

- Comos Muñoz, M. (s.f.). *Uso de inteligencia artificial en enfermería de urgencias y emergencias: revisión bibliográfica* (Repositorio Institucional).
<https://hdl.handle.net/20.500.12880/12999>
- 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>
- Garrido-Bueno, M., Fagundo-Rivera, J., Castillejo-del-Río, A., & Badillo-Sánchez, N. (2026). La Inteligencia Artificial en sanidad y su papel en la transformación de la práctica clínica, la formación y la Salud Pública. *Revista Española de Salud Pública*, 100, e202606033.
<https://dialnet.unirioja.es/servlet/articulo?codigo=10751508>
- Gil Ortiz, M. Á. (2025). *Revisión sistemática: El futuro del Triage de Urgencias en España, herramientas de triaje basadas en el uso de la IA* (Trabajo de fin de grado). Universidad Pontificia Comillas.
<https://repositorio.comillas.edu/xmlui/handle/11531/109918>
- Herrera Pacheco, D. A., & Terán Pino, E. F. (2024). *Estrategia basada en inteligencia artificial orientada al mejoramiento de la resolutividad médica disminuyendo el reingreso hospitalario en un servicio de urgencias* (Tesis de maestría, Universidad El Bosque). Repositorio Institucional Universidad El Bosque. <https://repositorio.unbosque.edu.co/items/ba03ed4b-7a4a-4310-84ab-5f932bfc70b2>
- 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. <https://doi.org/10.1136/wjps-2023-000580>
- 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.
<https://doi.org/10.1186/s12968-020-00678-x>
- 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.
<https://doi.org/10.1186/s12887-025-05412-w>
- León Chávez, A. F., & Duque Ortiz, J. D. (2024). *Descripción de las herramientas de inteligencia artificial, Deep Learning y Machine Learning empleadas en el aprendizaje del diagnóstico: Un nuevo enfoque en desarrollo de la valoración de signos y síntomas desde una revisión sistemática* (Revisión sistemática). Repositorio Institucional.
<https://hdl.handle.net/20.500.12495/12560>

- Leones Pico, J. N. (2023). Uso de inteligencia artificial clínica y calidad de la atención primaria. *Saber Estratégico Internacional*, 1(4), 20–36.
<https://doi.org/10.70577/s.e.v1i4.4>
- Luzuriaga, D. R. O., & Morales, V. E. B. (2025). Inteligencia Artificial en la gestión de los servicios de salud: Estado actual y perspectivas futuras. *ASCE MAGAZINE*, 4(2), 23. <https://dialnet.unirioja.es/servlet/articulo?codigo=10224519>
- Mina Curay, M. A., Mina Curay, C. E., Chicaiza Lozano, L. A., & Andrade Guamán, A. M. (2025). Aplicación de la inteligencia artificial (IA) en la práctica de la enfermería oportunidades y desafíos, una revisión sistemática. *RECIMUNDO*, 9(2), 4-16. [https://doi.org/10.26820/recimundo/9.\(2\).abril.2025.4-16](https://doi.org/10.26820/recimundo/9.(2).abril.2025.4-16)
- Muñoz Cofre, C. E., & Yáñez Zúñiga, D. L. (2026). Aplicaciones de la inteligencia artificial en atención primaria de salud: oportunidades y desafíos para América latina. *Revista Multidisciplinar Epistemología De Las Ciencias*, 3(2), 596-607. <https://doi.org/10.71112/kbqj4x03>
- 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.
<https://doi.org/10.3390/jcm13072089>
- Rogero Blanco, M. E., & López Rodríguez, J. A. (2026). Aplicaciones actuales y potenciales en la consulta del profesional de la medicina de familia. *FMC - Formación Médica Continuada en Atención Primaria*, 33(3, Supl. 1), 17-22.
<https://doi.org/10.1016/j.fmc.2026.02.005>
- Rubio, O., Vila, M., Escobar, M., & Agusti, A. (2025). ¿Cómo podría la inteligencia artificial mejorar la experiencia del paciente en el ámbito ambulatorio? Reflexiones del grupo JANUS. *Medicina Clínica*, 164(4), 190-195.
- Segur Ferrer, J., Guilabert, A., López Heras, D., Estrada-Sabadell, M. D., Barreda-Arnau, E., & Vivanco-Hidalgo, R. M. (2025). *Teledermatología asíncrona como mecanismo de triaje y derivación de pacientes entre atención primaria y especializada y para apoyar el diagnóstico de las afecciones dermatológicas* (Repositorio Institucional).
<http://hdl.handle.net/11351/13198>
- Valdés Martínez, J., & Barragán Cutiva, J. (2026). *Diseño de solución tecnológica de triaje médico inteligente adaptada al sistema de salud colombiano* (Trabajo de grado, Universidad Ean). Repositorio Universidad Ean.
<https://hdl.handle.net/10882/19085>
- Villa Feijoó, A. L., & Zapata Velasco, E. K. (2025). Aplicaciones de la inteligencia artificial en el diagnóstico médico basado en datos. *Innova Science Journal*, 3(1), 16-29. <https://doi.org/10.63618/omd/isj/v3/n1/2>
- Wang, J., et al. (2020). Intelligent diagnosis of heart murmurs in children with congenital heart disease. *Journal of Healthcare Engineering*, 2020, 1-9.
<https://doi.org/10.1155/2020/6612341>

Wang, J., et al. (2021). Automated interpretation of congenital heart disease from multi-view echocardiograms. *Medical Image Analysis*, 69, 101942.

<https://doi.org/10.1016/j.media.2021.101942>

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>