



Pontificia Universidad  
Católica del Ecuador | Sede  
Ambato

**ESCUELA DE SALUD Y BIENESTAR**

**Tema:**

**APLICACIONES DE LA INTELIGENCIA ARTIFICIAL EN LA INTERPRETACIÓN  
DE ESTUDIOS DE IMAGEN MÉDICA. REVISIÓN SISTEMÁTICA**

**Proyecto de investigación previo a la obtención del título de Médico General**

**Línea de investigación:**

**VIDA DIGNA Y SALUD INTEGRAL**

**Autor:**

Diego Josue Viera Jacome

**Directora:**

Esp. Blanca Belén Guilcapi Baldeón

**Ambato – Ecuador**

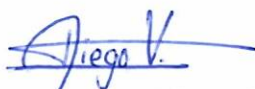
**Marzo 2026**

## DECLARACIÓN DE AUTENTICIDAD Y RESPONSABILIDAD

Yo: **DIEGO JOSUE VIERA JACOME**, con cédula de ciudadanía **1850240969**, autor del trabajo de titulación intitulado: "APLICACIONES DE LA INTELIGENCIA ARTIFICIAL EN LA INTERPRETACIÓN DE ESTUDIOS DE IMAGEN MÉDICA. REVISIÓN SISTEMÁTICA", previo a la obtención del título profesional de **MÉDICO GENERAL**, en la escuela de **SALUD Y BIENESTAR**.

1. Declaro tener pleno conocimiento de la obligación que tiene la Pontificia Universidad Católica del Ecuador, de conformidad con el artículo 144 de la Ley Orgánica de Educación Superior, de entregar a la SENESCYT en formato digital una copia del referido trabajo de graduación para que sea integrado al Sistema Nacional de Información de la Educación Superior del Ecuador para su difusión pública respetando los derechos de autor.
2. Autorizo a la Pontificia Universidad Católica del Ecuador a difundir a través del sitio web de la Biblioteca de la PUCE Ambato, el referido trabajo de graduación, respetando las políticas de propiedad intelectual de la Universidad.

Ambato, marzo 2026



Diego Josue Viera Jacome

CC. 1850240969

**PONTIFICIA UNIVERSIDAD CATÓLICA DEL ECUADOR  
SEDE AMBATO  
APROBACIÓN DEL TRIBUNAL DE GRADO**

**Tema:**

**APLICACIONES DE LA INTELIGENCIA ARTIFICIAL EN LA INTERPRETACIÓN  
DE ESTUDIOS DE IMAGEN MÉDICA. REVISIÓN SISTEMÁTICA**

**Línea de Investigación:**

**VIDA DIGNA Y SALUD INTEGRAL**

**Autor:**

Diego Josue Viera Jacome

Blanca Belén Guilcapi Baldeón, Méd. Esp.

CC. 0603941915

**CALIFICADOR**

f. 

Netty Paola Guevara Galarza, Méd. Esp.

**CALIFICADOR**

f. 

María José Gavilanes Llango, Méd. Esp.

**CALIFICADOR**

f. 

Freddy Patricio Mayorga Valle, Dr. Esp.

**DIRECTOR ESCUELA DE SALUD Y BIENESTAR**

f. 

Diego Gonzalo Coca Chanalata, Dr. Mg.

**PROSECRETARIO PUCE AMBATO**

f.   


**Ambato – Ecuador**

**Marzo 2026**

## DEDICATORIA

*Dedico esta tesis a mi familia, por ser mi apoyo incondicional y mi principal motivo para seguir adelante, por enseñarme con el ejemplo el valor de la constancia y el esfuerzo.*

*También la dedico a mí, por no rendirme, por aprender en el camino y por transformar los retos en crecimiento. Y a todas las personas que creen en la ciencia y en una medicina más segura y humana, donde la innovación aporte con responsabilidad al bienestar de los pacientes.*

**Diego Viera**

## **AGRADECIMIENTO**

*Agradezco, en primer lugar, a mi familia, por su apoyo constante, su paciencia y por acompañarme en cada etapa de este proceso, incluso en los momentos de mayor cansancio. Su confianza fue un motor esencial para mantenerme firme y culminar este trabajo.*

*De manera especial, agradezco a quienes facilitaron el acceso a recursos bibliográficos y bases de datos, y a todas las personas que, con una palabra de ánimo, apoyo técnico o acompañamiento emocional, contribuyeron a que esta investigación pudiera concretarse.*

**Diego Viera**

## RESUMEN

La imagenología médica sustenta el diagnóstico, pero el aumento del volumen de estudios y la escasez de personal incrementan la sobrecarga, la variabilidad interpretativa y los errores. La inteligencia artificial (IA) se plantea como apoyo para mejorar la precisión diagnóstica y el flujo de trabajo. Se realizó una revisión sistemática con búsqueda en bases biomédicas entre enero de 2020 y junio de 2025, según PRISMA 2020; se incluyeron estudios que evaluaron IA y reportaron rendimiento diagnóstico o efectos operativos.

La IA fue comparable o superior al radiólogo en tareas específicas de detección, clasificación y segmentación, especialmente como segundo lector o herramienta de triage, siendo la combinación radiólogo + IA el enfoque más robusto. Se observaron aumentos de falsos positivos y menor estabilidad ante variabilidad anatómica o hallazgos sutiles. Los efectos sobre la eficiencia fueron variables, desde reducción de tiempos de lectura y mejor priorización de urgencias hasta beneficios modestos o cargas transitorias por alertas y cambios organizativos. Predominaron diseños retrospectivos, validación interna y muestras poco diversas, con escasa medición de desenlaces clínicos.

En conclusión, la IA representa un avance sólido pero incompleto y debe integrarse como complemento del juicio radiológico, con supervisión humana. Se requieren estudios prospectivos multicéntricos con validación externa y métricas de equidad y explicabilidad; en América Latina y Ecuador, son prioritarios el fortalecimiento de la infraestructura digital, la gobernanza y la generación de datos locales.

**Palabras clave:** inteligencia artificial, aprendizaje automático, radiología, diagnóstico por imagen.

## ABSTRACT

*Medical imaging supports diagnosis, but the increase in the volume of studies and staff shortages increase overload, interpretative variability, and errors. Artificial intelligence (AI) is proposed as a support to improve diagnostic accuracy and workflow. A systematic review was conducted with a search of biomedical databases between January 2020 and June 2025, according to PRISMA 2020; studies that evaluated AI and reported diagnostic performance or operational effects were included.*

*AI was comparable or superior to radiologists in specific detection, classification, and segmentation tasks, especially as a second reader or triage tool, with the radiologist + AI combination being the most robust approach. Increases in false positives and lower stability in the face of anatomical variability or subtle findings were observed. The effects on efficiency were variable, ranging from reduced reading times and better prioritization of emergencies to modest benefits or transient burdens due to alerts and organizational changes. Retrospective designs, internal validation, and undiverse samples predominated, with little measurement of clinical outcomes.*

*In conclusion, AI represents a solid but incomplete advance and should be integrated as a complement to radiological judgment, with human supervision. Prospective multicenter studies with external validation and metrics of fairness and explainability are required. In Latin America and Ecuador, strengthening digital infrastructure, governance, and local data generation are priorities.*

**Keywords:** *artificial intelligence; machine learning; medical imaging; diagnostic imaging.*

## ÍNDICE GENERAL DE CONTENIDOS

DECLARACIÓN DE AUTENTICIDAD Y RESPONSABILIDAD.....	ii
APROBACIÓN DEL TRIBUNAL DE GRADO .....	iii
DEDICATORIA.....	iv
AGRADECIMIENTO.....	v
RESUMEN.....	vi
ABSTRACT .....	vii
INTRODUCCIÓN .....	1
CAPÍTULO I. ESTADO DEL ARTE Y LA PRÁCTICA .....	8
1.1. Definición .....	8
1.2. Inteligencia artificial.....	9
1.3. Antecedentes .....	11
1.4. Aplicaciones de IA en salud.....	13
CAPÍTULO II. DISEÑO METODOLÓGICO .....	20
2.1. Introducción .....	20
2.2. Estrategia metodológica.....	20
2.3. Resultados esperados .....	23
2.4. Consideraciones éticas.....	23
CAPÍTULO III. ANÁLISIS DE LOS RESULTADOS DE LA INVESTIGACIÓN .....	24
3.1. Características generales .....	24
3.2. Rendimiento diagnóstico y utilidad clínica.....	27
3.3. Impacto en la eficiencia y el flujo de trabajo.....	29
3.4. Calidad metodológica, sesgos y generalización de los modelos .....	30
CONCLUSIONES.....	39
RECOMENDACIONES .....	42
BIBLIOGRAFÍA .....	45

## ÍNDICE DE FIGURAS

Gráfico 1. Evolución de la inteligencia artificial.....	11
Gráfico 2. Principios éticos de consenso de la OMS para el uso de la IA en salud. .....	17
Gráfico 3. Diagrama PRISMA .....	23
Gráfico 4. Aplicaciones de IA según modalidad de imagen .....	26
Gráfico 5. Impacto de la IA en indicadores de eficiencia y flujo de trabajo .....	29

## ÍNDICE DE TABLAS

Tabla 1. Características generales de los estudios incluidos en la revisión.....	25
Tabla 2. Modalidades de imagen, subespecialidades y tareas dominantes de la IA. .....	26
Tabla 3. Síntesis cualitativa del impacto de la IA sobre el rendimiento diagnóstico .....	28
Tabla 4. Principales fuentes de sesgo y limitaciones metodológicas en los estudios de IA en imagen médica.....	31

## INTRODUCCIÓN

La imagenología médica se ha consolidado como uno de los pilares centrales de la medicina contemporánea. Estudios como la radiografía convencional, la tomografía computarizada (TC), la resonancia magnética (RM), la ecografía y la medicina nuclear permiten visualizar de manera no invasiva la anatomía y la fisiología, orientando el diagnóstico, el tratamiento y el seguimiento clínico de una amplia variedad de patologías. En las últimas décadas, el volumen de estudios de imagen se ha incrementado de forma exponencial, impulsado por el envejecimiento poblacional, la carga creciente de enfermedades crónicas y la disponibilidad ampliada de tecnología diagnóstica en diversos niveles de atención. Este aumento de la demanda no siempre se ha acompañado de un crecimiento proporcional en el número de radiólogos ni en los recursos organizativos necesarios, lo que genera sobrecarga de trabajo, listas de espera y riesgo de deterioro en la calidad de la atención (Anderson et al., 2022; Eisemann et al., 2025; Muhammad & Bendeche, 2024a).

Este desajuste entre demanda y capacidad diagnóstica se traduce en varios problemas: sobrecarga laboral de los profesionales de la imagen, variabilidad interobservador en la interpretación de estudios, retrasos en la emisión de informes y potencial incremento de errores diagnósticos. Tales factores afectan la seguridad del paciente, la oportunidad terapéutica y la eficiencia global de los sistemas de salud. En este escenario, las tecnologías digitales basadas en inteligencia artificial se presentan como herramientas con potencial para apoyar la interpretación de estudios de imagen, contribuir a la estandarización de procesos, priorizar casos urgentes y optimizar la utilización de recursos (Brady et al., 2024; Geis et al., 2019; Stogiannos et al., 2025).

La IA, entendida como el conjunto de métodos computacionales capaces de realizar tareas que tradicionalmente requerían juicio humano, ha avanzado de forma notable gracias al desarrollo del aprendizaje automático (*machine learning*) y, en particular, del aprendizaje profundo (*deep learning*). Las redes neuronales convolucionales (CNN), diseñadas para procesar información visual mediante la extracción jerárquica de patrones espaciales, han demostrado un rendimiento

elevado en tareas de clasificación y detección de hallazgos en imágenes médicas. Estas arquitecturas sustentan buena parte de los sistemas de diagnóstico asistido por computadora, con aplicaciones en la detección de nódulos pulmonares, tumores cerebrales, lesiones mamarias y múltiples patologías en distintos órganos(Han et al., 2024; Kohli et al., 2017; Puentes et al., n.d.; Stogiannos et al., 2025; Yoo et al., 2021).

La confluencia entre aumento del poder computacional, expansión de sistemas para almacenamiento y gestión de imágenes, y disponibilidad de grandes repositorios de datos ha favorecido una proliferación de estudios sobre IA en imagenología. Desde aproximadamente 10 años, el número de publicaciones relacionadas con IA aplicada a la interpretación de estudios de imagen médica ha crecido de manera acelerada, y se han descrito resultados prometedores en términos de sensibilidad, especificidad y área bajo la curva (AUC) en diversas tareas diagnósticas. Sin embargo, buena parte de esta evidencia se ha generado en entornos controlados, con diseños retrospectivos, muestras seleccionadas y validaciones limitadas, lo que plantea interrogantes sobre su traslado a la práctica clínica cotidiana(Han et al., 2024; Lawrence et al., 2025; Obuchowicz et al., 2025).

Más allá del desempeño algorítmico aislado, la implementación real de sistemas de IA en servicios de imagen enfrenta desafíos metodológicos, organizativos, éticos y regulatorios. Aunque múltiples estudios reportan resultados favorables en métricas intermedias, persiste incertidumbre acerca de su impacto sobre desenlaces clínicos relevantes, como mortalidad, discapacidad, tiempos hasta el tratamiento o reducción de eventos adversos. Además, existe preocupación por la generalización de los modelos a poblaciones y sistemas de salud diferentes a aquellos en los que fueron entrenados, por el potencial sesgo algorítmico y por la opacidad de muchos modelos de aprendizaje profundo, percibidos como “cajas negras”(Brady et al., 2024; de Vries et al., 2023; Stogiannos et al., 2025; World Health Organization (WHO), 2024).

En el plano internacional, organismos como la Organización Mundial de la Salud y marcos regulatorios recientes, como el Reglamento Europeo de Inteligencia Artificial, han comenzado a situar las aplicaciones de IA en salud, y específicamente

en imagenología, dentro de la categoría de sistemas de “alto riesgo”. Esto implica exigencias estrictas en materia de calidad de datos, transparencia, supervisión humana, gestión de riesgos y monitorización posdespliegue. Paralelamente, las sociedades científicas y los grupos de trabajo multisectoriales han enfatizado la necesidad de que la adopción de IA en radiología se alinee con principios de autonomía, equidad, responsabilidad, explicabilidad y protección de la privacidad de los pacientes (Becker et al., 2022; Geis et al., 2019; World Health Organization (WHO), 2024).

A nivel regional, la evidencia disponible sobre IA en imagen médica se concentra principalmente en centros académicos de países de altos ingresos. En América Latina, las experiencias descritas se orientan con frecuencia a proyectos puntuales, series de casos o iniciativas aisladas, con escasos estudios sistemáticos que evalúen el impacto clínico, organizativo y ético de estas herramientas en contextos reales de práctica. En países como Ecuador, la adopción de IA en salud se encuentra en una fase incipiente: se reconocen esfuerzos académicos y algunos desarrollos en instituciones específicas, pero persisten limitaciones relacionadas con infraestructura tecnológica, marcos regulatorios, formación de talento humano y disponibilidad de datos de alta calidad. Esta brecha geográfica y contextual plantea dudas sobre la aplicabilidad directa de los modelos desarrollados en entornos de alto recurso a sistemas de salud con restricciones, estructuras organizativas distintas y perfiles epidemiológicos particulares (Galarza Medina et al., 2024; Muhammad & Bendecheche, 2024a; Seyyed-Kalantari et al., 2021).

En este contexto, la interpretación de estudios de imagen médica constituye un campo crítico para analizar el verdadero aporte de la IA. Las aplicaciones descritas abarcan tareas de detección de hallazgos, clasificación de patologías, segmentación de estructuras anatómicas y priorización o triage de casos. La literatura reporta, en múltiples escenarios, un rendimiento comparable o superior al de radiólogos en tareas específicas, especialmente cuando la IA se integra como segundo lector o herramienta de apoyo. Sin embargo, no es claro en qué medida estos beneficios se traducen en mejoras sistemáticas en la calidad del proceso diagnóstico, la eficiencia del flujo de trabajo, la seguridad del paciente y la utilización racional de recursos, ni cuáles son las condiciones de implementación organizativa

que maximizan su desempeño y reducen riesgos(Brady et al., 2024; Kohli et al., 2017; Obuchowicz et al., 2025).

A la par de las promesas tecnológicas, emergen preocupaciones éticas y profesionales. El riesgo de automatización acrítica de decisiones, la posible erosión de la autonomía profesional, la dependencia excesiva de herramientas opacas y la reproducción de desigualdades a través de sesgos de datos son aspectos recurrentemente señalados. Además, la aceptación social y profesional de la IA en imagenología no depende únicamente del rendimiento técnico, sino también de la claridad en la distribución de responsabilidades, la explicabilidad de las decisiones y la garantía de que la supervisión humana significativa se mantenga como elemento central del proceso diagnóstico(Nagendran et al., 2020; Stogiannos et al., 2025; World Health Organization (WHO), 2024).

Estas tensiones nos dan una brecha de conocimiento relevante. Por un lado, existe una producción creciente de investigaciones que reportan métricas de rendimiento de modelos de IA en la interpretación de estudios de imagen. Por otro, se reconoce la ausencia de síntesis rigurosas y actualizadas que integren, de forma crítica, la evidencia disponible sobre tres dimensiones clave: a) el impacto de la IA en la precisión diagnóstica; b) su efecto sobre la eficiencia y la carga de trabajo en los servicios de imagen; y c) las implicaciones clínicas, éticas y organizativas de su implementación. Asimismo, se identifica como insuficiente la evaluación sistemática de la calidad metodológica de los estudios, la robustez de la validación externa y la capacidad de los modelos para generalizar a distintas poblaciones y escenarios(Brady et al., 2024; Krishna NK et al., 2025; Obuchowicz et al., 2025).

En el ámbito latinoamericano y, en particular, en Ecuador, esta brecha se amplifica. La falta de revisiones sistemáticas centradas en aplicaciones de IA en la interpretación de estudios de imagen, que incluyan investigaciones recientes y que aborden de manera integrada aspectos de rendimiento diagnóstico, eficiencia operativa y gobernanza ética, limita la toma de decisiones informada por evidencia. Sin un panorama claro de fortalezas, limitaciones y vacíos de investigación, resulta difícil definir prioridades de inversión, diseñar políticas de adopción responsable y

orientar estrategias de formación para radiólogos, gestores y decisores en salud(Galarza Medina et al., 2024; Gómez Rodríguez et al., n.d.).

Frente a este escenario, es necesario realizar un ejercicio de síntesis crítica que permita responder a preguntas fundamentales: en pacientes sometidos a estudios de imagen médica, hasta qué punto el uso de herramientas de IA para apoyar la interpretación de las imágenes, en comparación con la interpretación convencional sin IA, mejora la calidad del proceso diagnóstico por imagen en términos de precisión diagnóstica, eficiencia (tiempos y carga de trabajo), decisiones clínicas derivadas, utilización de recursos y seguridad del paciente. Esta pregunta de investigación se inscribe en el marco de la medicina basada en la evidencia y busca articular el análisis de desenlaces cuantitativos con la reflexión sobre las condiciones de uso seguro, ético y equitativo de la IA(Geis et al., 2019; Obuchowicz et al., 2025).

Desde el punto de vista conceptual, el presente trabajo se apoya en varios ejes. En primer lugar, la calidad del proceso diagnóstico por imagen se entiende como la combinación de precisión técnica (sensibilidad, especificidad, exactitud, AUC), eficiencia operativa (tiempos de lectura, organización de flujos de trabajo, carga de tareas), seguridad del paciente (reducción de errores diagnósticos clínicamente relevantes, disminución de falsos negativos y control de falsos positivos que conduzcan a intervenciones innecesarias) y equidad en el acceso y desempeño. En segundo lugar, la IA en imagenología se concibe como un conjunto de herramientas que actúan sobre distintas etapas del flujo de trabajo radiológico: desde la detección automatizada de hallazgos en imágenes brutas, pasando por la segmentación y cuantificación de estructuras, hasta la priorización de casos en listas de lectura y, en algunos sistemas, la generación asistida de informes. En tercer lugar, se incorpora la noción de explicabilidad y transparencia como condición para la aceptabilidad clínica y social, entendiendo que modelos opacos incrementan la dificultad para auditar decisiones, comunicar riesgos y atribuir responsabilidades(Brady et al., 2024; Champendal et al., 2023; Kohli et al., 2017; Muhammad & Bendeche, 2024a; Stogiannos et al., 2025).

La justificación de este trabajo se sostiene en varios aspectos. En el plano clínico, sintetizar la evidencia existente sobre IA en la interpretación de estudios de imagen médica permite a radiólogos, clínicos y gestores disponer de un panorama estructurado de beneficios y limitaciones, evitando decisiones basadas únicamente en promesas tecnológicas o en experiencias aisladas. En el ámbito epidemiológico y de políticas de salud, contar con una visión integrada de los efectos de la IA sobre la precisión diagnóstica, la eficiencia del flujo de trabajo y la seguridad del paciente contribuye a priorizar intervenciones, planificar inversiones y definir criterios para la adopción responsable de estas herramientas en sistemas con recursos limitados. Desde la perspectiva metodológica, la evaluación sistemática de la calidad de los estudios incluidos y de la robustez de la validación externa de los modelos ayuda a identificar debilidades recurrentes y a proponer lineamientos para futuras investigaciones. Finalmente, en términos sociales y éticos, la revisión de implicaciones relacionadas con equidad, explicabilidad y gobernanza de la IA en imagenología aporta elementos para el debate sobre la incorporación de tecnologías emergentes en contextos donde la protección de derechos y la reducción de desigualdades deben permanecer como prioridades centrales (Galarza Medina et al., 2024; Geis et al., 2019; Stogiannos et al., 2025).

En este marco, el objetivo general de la presente revisión sistemática es sintetizar la evidencia científica disponible sobre las aplicaciones de la inteligencia artificial en la interpretación de estudios de imagen médica, evaluando la calidad metodológica de los estudios incluidos y consolidando la información para orientar futuras investigaciones y la práctica clínica.

Como objetivos específicos, se plantean:

- Describir los principales tipos de aplicaciones de inteligencia artificial utilizadas en la interpretación de imágenes médicas, con el fin de identificar sus áreas de mayor desarrollo e implementación.
- Evaluar el impacto de la inteligencia artificial en la precisión diagnóstica de estudios imagenológicos, con el fin de establecer su contribución en la detección temprana y el seguimiento de enfermedades.

- Analizar las implicaciones clínicas y éticas del uso de inteligencia artificial en la interpretación de estudios de imagen médica, con el fin de valorar sus beneficios, limitaciones y retos futuros.

## CAPÍTULO I. ESTADO DEL ARTE Y LA PRÁCTICA

### 1.1. Definición

La imagenología médica se define como el conjunto de técnicas (la radiografía convencional, la tomografía computarizada (TC), la resonancia magnética (RM), la ecografía y la medicina nuclear) que permiten visualizar de forma no invasiva la anatomía y fisiología de los órganos y tejidos en el cuerpo humano para apoyar el diagnóstico, tratamiento y seguimiento clínico. Según Najjar (2023), la radiología moderna “constituye un pilar esencial de la medicina contemporánea, pues va más allá de la simple detección de enfermedades al abarcar también la guía terapéutica y el monitoreo evolutivo de los pacientes” (Najjar, 2023).

La imagenología moderna enfrenta un desafío creciente: el aumento exponencial en el volumen de estudios de imagen (radiografías, TC, RM y mamografías) exige interpretaciones rápidas y precisas, mientras que la disponibilidad de radiólogos es limitada en muchos sistemas de salud. Esta presión ha abierto la puerta a soluciones tecnológicas como la inteligencia artificial (IA), que promete contribuir al diagnóstico, reducir tiempos de lectura y apoyar el flujo de trabajo (Obuchowicz et al., 2025).

El problema no es solo de capacidad, sino también de calidad y equidad. La variabilidad interobservador, la sobrecarga laboral y los sesgos diagnósticos ponen en riesgo la seguridad del paciente (World Health Organization (WHO), 2024). La IA se plantea como una herramienta capaz de estandarizar y aumentar la eficiencia, pero la literatura revela resultados heterogéneos (D'antonoli, 2020). La pregunta que emerge es clara: ¿hasta qué punto la integración de IA en la interpretación de estudios de imagen mejora el rendimiento diagnóstico y la eficiencia clínica, sin generar riesgos adicionales para el paciente? Esta cuestión se entrelaza con subtemas como la aceptabilidad de la tecnología, su impacto en la educación médica y la gobernanza ética y regulatoria de su uso (Aldhafeeri, 2025).

## 1.2. Inteligencia artificial

La inteligencia artificial (IA) se define como el conjunto de métodos y algoritmos computacionales diseñados para reproducir procesos cognitivos humanos, tales como el razonamiento, la percepción, la resolución de problemas y el aprendizaje, mediante el análisis automatizado de grandes volúmenes de datos. Su propósito principal es permitir que los sistemas informáticos ejecuten tareas que tradicionalmente requieren juicio humano, desde la interpretación visual hasta la toma de decisiones clínicas complejas (Najjar, 2023).

Dentro de este marco, el aprendizaje automático (ML) y su subcampo más avanzado, el aprendizaje profundo (DL), constituyen los pilares del desarrollo contemporáneo. Ambos se basan en la capacidad de los algoritmos para identificar patrones y correlaciones no evidentes a través del entrenamiento interactivo sobre conjuntos masivos de datos etiquetados (Azizi et al., 2023).

El ML emplea modelos estadísticos capaces de generalizar comportamientos a partir de datos previos. En medicina, esta técnica se aplica al reconocimiento de imágenes, la predicción de riesgo clínico y la estratificación de pacientes. Su eficacia radica en la capacidad de ajustar los parámetros del modelo a medida que se incorporan nuevos datos, mejorando continuamente la precisión de sus predicciones. Por su parte, el DL utiliza redes neuronales artificiales multicapa, que simulan la estructura jerárquica del cerebro humano para procesar información de manera no lineal. Estas redes se componen de unidades interconectadas (neuronas artificiales) organizadas en capas, capaces de aprender características cada vez más abstractas de los datos mediante un proceso de retroalimentación del error (Najjar, 2023).

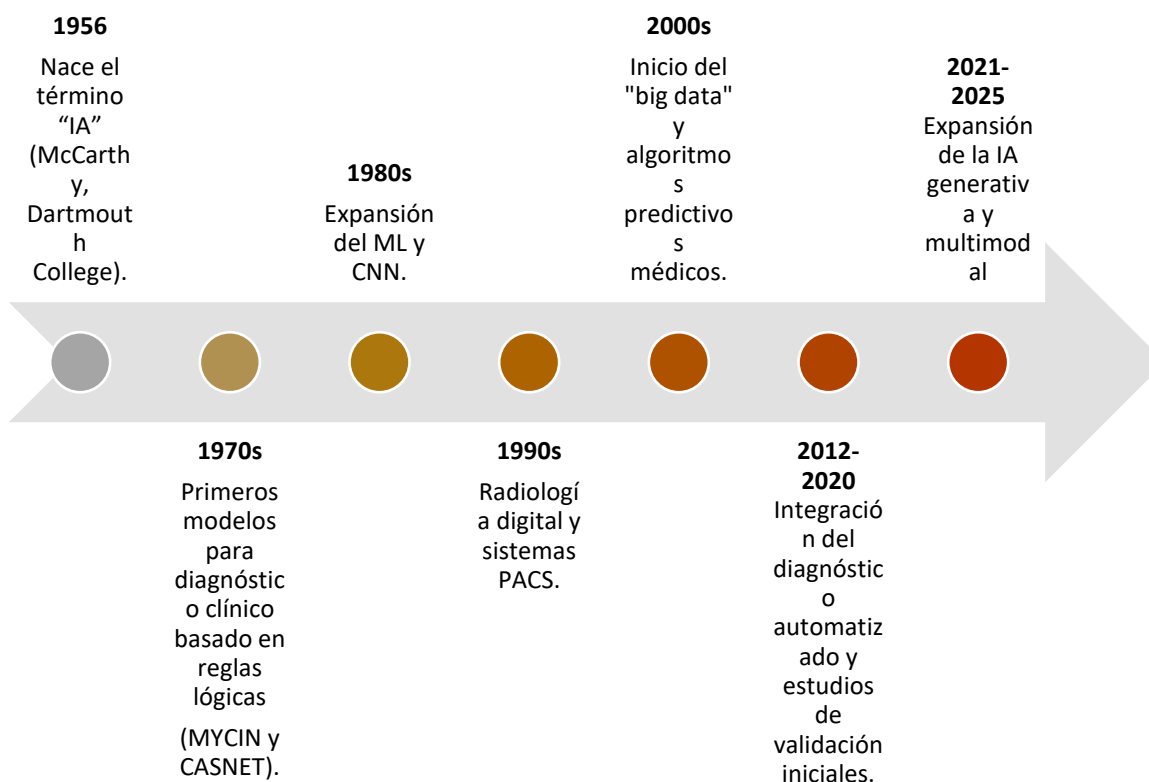
Entre las arquitecturas más influyentes del DL se destacan las redes neuronales convolucionales (CNN, Convolutional Neural Networks), especialmente útiles para el análisis de imágenes médicas. Las CNN aplican filtros o “convoluciones” que extraen patrones espaciales jerárquicos, como bordes, texturas y formas, permitiendo detectar estructuras anatómicas o anomalías con un rendimiento

comparable, e incluso superior, al de los radiólogos en tareas específicas de clasificación y detección (Najjar, 2023). Estas redes se han convertido en el núcleo de la mayoría de los sistemas de diagnóstico asistido por computadora (CAD) y han permitido avances significativos en la detección de tumores, hemorragias cerebrales y nódulos pulmonares, así como en la segmentación automática de tejidos y órganos en TC y RM (Azizi et al., 2023).

La evolución de la IA en imagenología ha estado impulsada por el aumento del poder computacional, el desarrollo de unidades de procesamiento gráfico (GPU) y la disponibilidad de bases de datos médicas extensas y validadas (Obuchowicz et al., 2025). Este ecosistema ha favorecido la transición de modelos experimentales a soluciones clínicamente viables. Sin embargo, como señalan Stogiannos et al. (2025), la implementación de la IA en entornos hospitalarios reales enfrenta todavía limitaciones de generalización, interoperabilidad y validación externa, por lo que su integración requiere un enfoque ético y metodológico riguroso (Stogiannos et al., 2025).

### 1.3. Antecedentes

**Gráfico 1.** Evolución de la inteligencia artificial.



MYCIN: sistema experto pionero que utilizaba razonamiento inverso.

CASNET (Causal Associational Network.): sistema basado en redes causales para diagnóstico y manejo.

PACS (Picture Archiving and Communication System): sistema digital para almacenar, gestionar y visualizar imágenes médicas (TC, RM, Rx, etc.).

Big Data: grandes volúmenes de datos complejos analizados con técnicas avanzadas para extraer patrones.

Fuente: elaboración propia

El desarrollo de la IA en el ámbito médico tiene sus raíces en la segunda mitad del siglo XX, cuando surgieron los primeros sistemas expertos orientados a apoyar la toma de decisiones clínicas mediante el uso de reglas lógicas y bases de conocimiento. Estos sistemas, como MYCIN y CASNET, fueron diseñados para imitar el razonamiento clínico humano a través de inferencias basadas en datos, representando un avance significativo para su época, aunque limitados por la capacidad computacional y la escasez de datos disponibles (Najjar, 2023).

Durante las décadas de 1980 y 1990, la IA médica experimentó una evolución progresiva impulsada por tres factores determinantes: el incremento del poder

computacional, la disponibilidad de grandes volúmenes de datos digitalizados (*big data*) y los avances en algoritmos de aprendizaje profundo. Esta convergencia permitió superar las restricciones de los sistemas expertos tradicionales y dio origen a una nueva generación de modelos capaces de aprender directamente de los datos, mejorar su rendimiento con la experiencia y ejecutar tareas de clasificación, detección y predicción con precisión cada vez mayor (Najjar, 2023).

Estas nuevas arquitecturas emulan la organización jerárquica del cerebro humano, procesando patrones visuales a través de múltiples capas que extraen características progresivamente más abstractas. Gracias a ello, las CNN lograron desempeños comparables, e incluso superiores, al juicio humano en tareas de clasificación de imágenes médicas y detección de lesiones, consolidando su papel como herramienta diagnóstica complementaria (Neri et al., 2019).

Con la transición hacia la radiología digital y el desarrollo de sistemas PACS (Picture Archiving and Communication System), la imagenología se transformó en un entorno ideal para la aplicación de IA. La gran cantidad de datos generados diariamente en hospitales y centros de diagnóstico proporcionó el insumo perfecto para entrenar modelos capaces de identificar patrones invisibles al ojo humano, optimizar flujos de trabajo y reducir la carga asistencial (Velamala et al., 2025).

En las últimas dos décadas, la IA ha pasado de ser un concepto experimental a una tecnología integrada en la práctica médica. Aplicaciones como la detección automatizada de nódulos pulmonares, la segmentación de tumores cerebrales o el cribado mamográfico asistido por algoritmos reflejan el grado de madurez alcanzado (Aldhafeeri, 2025; Kocak et al., 2025). Sin embargo, se advirtió una limitada validación externa y un riesgo de sesgo elevado, lo que dio lugar a la brecha entre el rendimiento experimental y la aplicación clínica real (Kelly et al., 2022).

#### 1.4. Aplicaciones de IA en salud

La IA ha transformado de manera progresiva el panorama de la medicina moderna, posicionándose como una de las tecnologías con mayor capacidad de impacto transversal en la atención sanitaria. Su aplicación abarca desde la genómica y la bioinformática, pasando por la patología digital, la dermatología y la oftalmología, hasta especialidades complejas como la neurología, la oncología y, con especial relevancia, la imagenología médica. En disciplinas altamente dependientes de datos, la capacidad de los algoritmos para detectar patrones invisibles al ojo humano ha impulsado innovaciones diagnósticas y terapéuticas. Estudios recientes subrayan que la integración de IA en la práctica clínica promete una herramienta para la reducción de carga de trabajo, optimización de tiempos y mayor precisión diagnóstica (Wenderott et al., 2024).

En diagnóstico y cuidado clínico, los modelos actuales apoyan tareas como estratificación de riesgo, apoyo a la decisión terapéutica y priorización clínica (p.ej., sospecha de sepsis, eventos cardiovasculares), además de síntesis de notas y antecedentes relevantes para la visita; estos usos apuntan a reducir retrasos, homogenizar criterios y mejorar continuidad asistencial (Iglesias López, n.d.-a).

En aplicaciones centradas en el paciente, la IA impulsa asistentes conversacionales para educación en salud, apoyo al autocuidado de crónicos (recordatorios, ajustes básicos de planes de acción) y facilitación del acceso a ensayos clínicos; estos sistemas pueden mejorar comprensión, adherencia y navegación del sistema sanitario cuando se diseñan con salvaguardas de calidad de información (World Health Organization (WHO), 2024).

En funciones tanto clínicas como administrativas, se han descrito ganancias al automatizar transcripción y redacción de notas clínicas, resumen de episodios previos, conciliación de medicación y traducción médico–paciente en tiempo real, lo que libera tiempo clínico directo y disminuye la carga administrativa (World Health Organization (WHO), 2024).

En educación médica, la IA permite tutores adaptativos, generación de guías clínicas y simulaciones de entrevista/razonamiento con retroalimentación inmediata; reportes recientes muestran alta utilidad percibida por estudiantes y necesidad de formación crítica para un uso responsable y complementario del aprendizaje tradicional (Yaynishet et al., 2024).

En investigación y desarrollo (I+D) de fármacos, se destacan la búsqueda y síntesis de literatura, minería de datos clínicos, diseño de moléculas y priorización de dianas; estos flujos aceleran hipótesis y selección de compuestos, con beneficios potenciales en costos y tiempos de I+D biomédica(Koçak et al., 2025).

Más allá, la Organización Mundial de la Salud ha identificado a los modelos multimodales de gran escala como herramientas con potencial que no es consistente en atención médica, investigación y educación, pero también advierte sobre riesgos éticos y regulatorios, como sesgos, degradación de competencias profesionales y desigual acceso (World Health Organization (WHO), 2024). Este equilibrio entre promesa y cautela marca la pauta de la incorporación de IA en medicina.

El organismo internacional también establece que la adopción ética de la IA debe guiarse por seis principios esenciales: autonomía, bienestar, transparencia, responsabilidad, equidad y sostenibilidad. Dichos principios buscan garantizar que las innovaciones digitales beneficien a todos los pacientes sin comprometer la seguridad, la privacidad ni la confianza en el sistema sanitario (World Health Organization (WHO), 2024).

### **Aplicaciones IA en imagen**

La imagenología, por su naturaleza digital y el crecimiento exponencial del volumen de estudios de imagen, se convirtió en un campo idóneo para la aplicación temprana de IA. La literatura describe cómo desde el 2015 en adelante la cantidad de investigaciones en IA aplicada a imagen médica se ha incrementado de manera

acelerada, situando a esta disciplina a la vanguardia de la transformación tecnológica en medicina (Kelly et al., 2022).

La IA médica fundamentada en el aprendizaje automático y el aprendizaje profundo, especialmente como antes mencionado mediante redes neuronales convolucionales, útiles para clasificación y segmentación (Azizi et al., 2023). Paralelamente, la radiómica permite extraer características cuantitativas de las imágenes, integrándolas con datos clínicos y genómicos para la medicina personalizada (Najjar, 2023).

La inteligencia artificial explicable (XAI, por sus siglas en inglés) surge como una respuesta indispensable a uno de los mayores desafíos contemporáneos en la aplicación de la inteligencia artificial en medicina: la opacidad de los modelos de aprendizaje profundo. A diferencia de los sistemas tradicionales, cuyas decisiones pueden ser rastreadas mediante reglas lógicas explícitas, los modelos basados en redes neuronales profundas (como las CNN o los transformers multimodales) operan a través de millones de parámetros interconectados que generan resultados de difícil interpretación incluso para los propios desarrolladores. Esta falta de transparencia ha sido denominada el problema de la “caja negra”, y constituye una amenaza tanto para la confianza clínica como para la seguridad del paciente, al dificultar la comprensión de cómo y por qué un algoritmo alcanza una determinada conclusión diagnóstica (Obuchowicz et al., 2025). Como se señala, “la falta de interpretabilidad no es solo un reto técnico, sino también un problema ético y regulatorio” (Aldhafeeri, 2025).

La XAI tiene como objetivo abrir esta caja negra, proporcionando mecanismos que permitan comprender, auditar y validar las decisiones algorítmicas. En el contexto de la imagenología médica, esto se traduce en herramientas que ofrecen mapas de calor o visualizaciones de atención (como Grad-CAM o *saliency maps*) que muestran qué regiones de una imagen influyeron en la predicción del modelo. Estos métodos facilitan la verificación por parte del radiólogo, incrementan la confianza en los resultados y contribuyen a la seguridad diagnóstica, especialmente en

escenarios donde las decisiones automatizadas pueden tener consecuencias clínicas significativas (Pinto-Coelho, 2023).

La interpretación de estudios de imagen constituye un escenario crítico donde la IA puede aportar beneficios tangibles. Sus aplicaciones abarcan tareas como la detección de hallazgos, la clasificación de patologías, la segmentación de estructuras anatómicas y la priorización de casos urgentes. Estos avances se traducen en la reducción de la variabilidad interobservador y la mejora en la precisión diagnóstica (Najjar, 2023).

No obstante, la integración clínica de estas soluciones no es homogénea y enfrenta múltiples barreras, como la variabilidad en los diseños metodológicos, la ausencia de validaciones externas robustas y la falta de transparencia de algunos modelos, lo que alimenta el debate sobre su confiabilidad (Champendal et al., 2023; Muhammad & Bendeche, 2024b).

### **Aspectos éticos y legales**

Los aspectos éticos y legales en el uso de la IA aplicada a la imagenología constituyen una preocupación creciente dentro de la gobernanza sanitaria global. La Organización Mundial de la Salud (OMS) ha establecido principios rectores que buscan equilibrar la innovación tecnológica con la protección de los derechos humanos y la seguridad del paciente. En su documento "*Ethics and Governance of Artificial Intelligence for Health*" (2024), la OMS establece seis principios fundamentales: proteger la autonomía, promover el bienestar y la seguridad, garantizar transparencia y explicabilidad, fomentar la responsabilidad, asegurar la equidad e inclusión, y promover la sostenibilidad (World Health Organization (WHO), 2024).

**Gráfico 2.** Principios éticos de consenso de la OMS para el uso de la IA en salud.



Fuente: modificado a partir de World Health Organization (2024).

Estos lineamientos constituyen un marco internacional de referencia que orienta a los Estados y a las instituciones sanitarias sobre el desarrollo, implementación y supervisión ética de los sistemas de IA en salud.

En el plano legal, aunque aún no existe una ley internacional vinculante específica para la IA en imagenología médica, organismos como la OMS y la Unión Europea han avanzado en directrices regulatorias. El Reglamento Europeo de Inteligencia Artificial (AI Act), aprobado en 2024, representa el primer intento global de establecer un marco jurídico para los sistemas de IA de alto riesgo, incluyendo los dispositivos médicos inteligentes utilizados en radiología. Este reglamento exige que los algoritmos sean auditables, trazables y diseñados con criterios de seguridad clínica, transparencia y supervisión humana en todo momento (Stogiannos et al., 2025).

De forma complementaria, la Society of Nuclear Medicine and Molecular Imaging ha enfatizado que el desarrollo de dispositivos médicos impulsados por IA debe entenderse como un “contrato social” entre investigadores, clínicos, pacientes y la sociedad, orientado a asegurar una distribución justa de beneficios y riesgos (Herington et al., 2023). Esto implica obligaciones éticas en tres dominios: el bienestar individual (no maleficencia y beneficencia), la autonomía

(consentimiento informado, privacidad de datos) y la justicia social, garantizando que las herramientas de IA no profundicen desigualdades preexistentes.

En este plano, la responsabilidad sobre las decisiones derivadas de IA sigue siendo objeto de debate. La literatura destaca riesgos en privacidad de datos, sesgos que afectan a poblaciones vulnerables y desafíos en la distribución equitativa de beneficios(Aldhafeeri, 2025; World Health Organization (WHO), 2024). Asimismo, la opacidad de los algoritmos dificulta su aceptación. La necesidad de técnicas de XAI ha sido enfatizada como un requisito indispensable para garantizar transparencia, confianza y cumplimiento regulatorio(Champendal et al., 2023; Muhammad & Bendechange, 2024b). La necesidad de explicabilidad trasciende lo técnico y se adentra en el terreno ético y regulatorio. Según Herington et al. (2023), “la falta de interpretabilidad no es solo un reto técnico, sino también un problema ético y regulatorio”, dado que impide atribuir responsabilidades claras y limita el derecho del paciente a comprender cómo se generan las decisiones médicas que le afectan(Herington et al., 2023).

## **IA en Ecuador**

El país se encuentra en una fase inicial de adopción de la inteligencia artificial, con un desarrollo aún limitado por la ausencia de políticas públicas específicas, recursos económicos y personal técnico especializado. Mientras potencias como China, Estados Unidos o la Unión Europea lideran la llamada “cuarta revolución industrial”, en América Latina destacan Brasil, Chile, Uruguay, Argentina y México, dejando a Ecuador totalmente atrás en términos de implementación tecnológica(Galarza Medina et al., 2024).

A pesar de estas limitaciones, varias universidades ecuatorianas han comenzado investigaciones sobre IA en distintos campos, incluyendo la medicina y las ciencias aplicadas. Además, algunas empresas del sector comercial, bancario y de ciberseguridad ya aplican herramientas basadas en IA. En el ámbito sanitario, el Instituto Ecuatoriano de Seguridad Social (IESS) desarrolló durante la pandemia de COVID-19 un sistema automatizado de diagnóstico médico, lo que en su momento

posicionó a Ecuador como el primer país de Sudamérica en ejecutar una herramienta diagnóstica mediada por IA(Galarza Medina et al., 2024).

Asimismo, existen proyectos nacionales destacados, como el uso combinado de IA y ecoendoscopia para reconocer estructuras anatómicas en vivo, galardonado a nivel internacional. Sin embargo, no hay patentes registradas relacionadas con inteligencia artificial, lo que facilita la investigación, pero refleja un vacío en la protección de propiedad intelectual tecnológica(Galarza Medina et al., 2024).

La creciente incorporación de la inteligencia artificial en la interpretación de estudios de imagen médica plantea tanto oportunidades como retos concretos. Más allá del entusiasmo tecnológico, es clave examinar con mirada crítica su verdadero impacto en la práctica clínica. Además, su implementación no puede entenderse sin considerar las limitaciones metodológicas de los estudios actuales, junto con las implicaciones éticas y regulatorias aún en debate. Se busca ir más allá de las promesas para identificar en qué condiciones la IA puede convertirse en un verdadero apoyo para los radiólogos y un avance real hacia una atención médica más precisa, ágil y confiable(Kelly et al., 2022; Lawrence et al., 2025; Zanardo et al., 2024).

## **CAPÍTULO II. DISEÑO METODOLÓGICO**

### **2.1. Introducción**

Las revisiones sistemáticas constituyen una herramienta esencial para sintetizar el conocimiento disponible sobre una temática determinada en el ámbito de las ciencias médicas. Su elaboración rigurosa permite responder preguntas de investigación de manera transparente, objetiva y reproducible, favoreciendo la toma de decisiones basadas en evidencia. La Declaración PRISMA 2020 (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) proporciona un marco estandarizado para garantizar la exhaustividad y claridad en el reporte de este tipo de estudios (Page et al., 2021).

### **2.2. Estrategia metodológica**

#### **Criterios de elegibilidad**

Los criterios de inclusión considerados fueron: estudios originales de diseño observacional como estudios de cohortes, casos y controles, estudios transversales, ensayos clínicos aleatorizados prospectivos/retrospectivos de implementación, revisiones sistemáticas y metaanálisis, investigaciones realizadas en seres humanos de cualquier sexo y grupo etario, relacionadas con herramientas de inteligencia artificial aplicadas a la interpretación de imágenes médicas (detección, clasificación, segmentación, localización, priorización/triage) en radiografía, TC, RM, ecografía, mamografía o PET-CT, con comparadores apropiados (lectura estándar del radiólogo, atención habitual, placebo o ausencia de intervención) y que reportaran al menos un desenlace relevante: rendimiento diagnóstico (sensibilidad, especificidad, AUC, exactitud), impacto en flujo de trabajo (tiempo de lectura, tasa de priorización), efectos clínicos o de seguridad (cambios de manejo, Falso positivo/Falso negativo), calibración/generalización o validación externa; que incluyeran comparadores como placebo, tratamiento estándar, ausencia de intervención u otras alternativas; que reportaran resultados clínicos, imagenológicos o de calidad de vida relevantes al objetivo de la revisión; artículos científicos que hayan sido publicados desde enero 2020 hasta junio 2025 que estén

disponibles tanto en repositorios públicos como privados, publicados en idioma inglés, español y portugués.

Los criterios de exclusión fueron: estudios publicados hasta antes de enero 2020; artículos con diseño metodológico insuficiente; opiniones de expertos, editoriales, cartas al editor, resúmenes de congreso y literatura gris no validada; estudios duplicados o con datos redundantes reportados previamente en publicaciones ya incluidas; y artículos en idiomas distintos al inglés, español y portugués.

### **Fuentes de información y búsqueda**

Se consultaron las siguientes bases de datos electrónicas: PubMed/MEDLINE, Scopus, Web of Science, Cochrane Library, Nature y SciELO. Asimismo, se revisaron registros de ensayos clínicos y literatura gris. Las estrategias de búsqueda incluyeron el uso de descriptores MeSH/DeCS “Artificial Intelligence”/“Inteligencia Artificial”, “Machine Learning”/“Aprendizaje Automático”, “Radiology”/“Radiología”, “Diagnostic Imaging”/“Diagnóstico por Imagen”, “Image Interpretation”, combinados mediante operadores booleanos (AND, OR).

### **Estrategia de selección**

La selección de estudios se realizó en dos fases: cribado inicial de títulos y resúmenes, seguido de revisión a texto completo. El proceso fue llevado a cabo por revisores de manera independiente. El flujo de selección se documentó mediante el diagrama PRISMA 2020, que incluye identificación, cribado, elegibilidad e inclusión.

### **Extracción de datos**

La información de los estudios incluidos se extrajo de manera independiente por los autores utilizando un formulario estandarizado, diseñado para mantener la uniformidad y reducir errores en el proceso. Se registró la identificación del estudio (autor/es, año de publicación, país, revista) y se consignó la pregunta de

investigación en formato PICO, definiendo con claridad la población (P): “Pacientes indistintamente de género y edad, sometidos a estudios de imagen médica (TC, RM, RX, Mamografía, PET/SPECT, Ecografía.)”, la intervención (I): “Uso de herramientas de IA para apoyar la interpretación de las imágenes.”, el comparador (C): “Interpretación convencional sin apoyo de IA” y los resultados de interés (O): “Impacto global de la IA sobre la calidad del proceso diagnóstico por imagen, incluyendo precisión diagnóstica, tiempos y carga de trabajo, decisiones clínicas derivadas, utilización de recursos y seguridad del paciente.”. En este marco, la pregunta se formula de la siguiente manera; “¿En pacientes sometidos a estudios de imagen médica, el uso de herramientas de inteligencia artificial para apoyar la interpretación de las imágenes, en comparación con la interpretación convencional sin apoyo de IA, mejora la calidad del proceso diagnóstico por imagen en términos de precisión diagnóstica, eficiencia (tiempos y carga de trabajo), decisiones clínicas derivadas, utilización de recursos y seguridad del paciente?”

Adicionalmente, se registró el diseño metodológico y las principales características de cada estudio en una tabla resumen que incluyó: referencia, título, identificación, objetivos, diseño del estudio, método, descripción de los grupos experimental y de control, resultados, información sobre la intervención, elementos de discusión y conclusiones, así como la revista en la que fue publicado, su indexación, la base de datos de procedencia y el enlace de acceso.

En relación con los resultados, se extrajeron los desenlaces principales y secundarios, especificando las medidas de rendimiento empleadas (por ejemplo, sensibilidad, especificidad, exactitud, área bajo la curva, valores predictivos u otras métricas diagnósticas o de desempeño) y la forma en que fueron reportadas. Asimismo, se resumió de forma narrativa la información clave y los hallazgos de cada estudio, sin realizar en esta fase un análisis estadístico combinado ni metaanálisis. Cuando estuvo disponible, se registraron las principales conclusiones de los autores, las implicaciones clínicas o metodológicas señaladas, así como las limitaciones reconocidas en cada artículo.

## 2.3. Resultados esperados

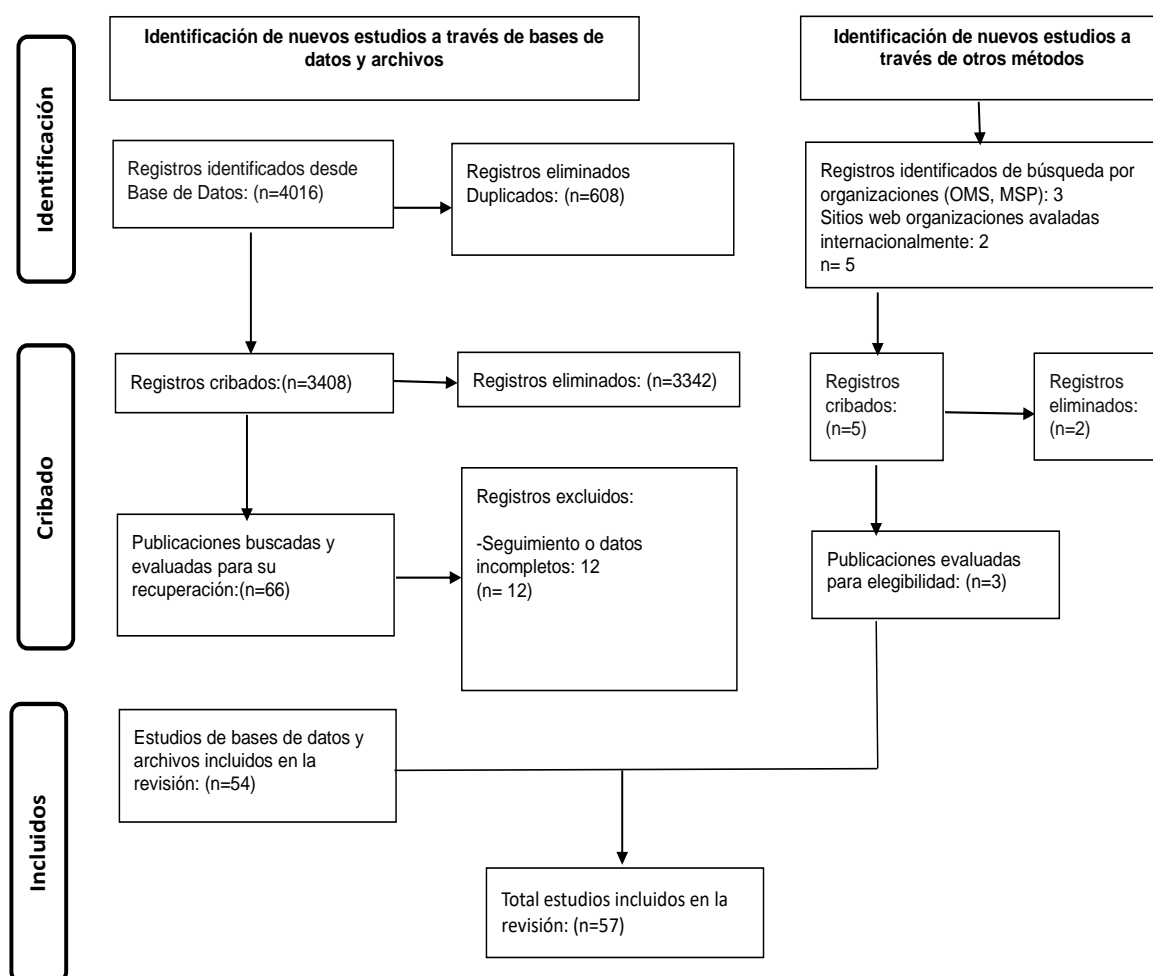
Se espera obtener una síntesis crítica de la literatura existente sobre [tema de interés], identificando fortalezas, limitaciones y vacíos de conocimiento que permitan orientar tanto la práctica clínica como la investigación futura.

## 2.4. Consideraciones éticas

Al tratarse de una revisión sistemática sin intervención directa en seres humanos, no se requirió consentimiento informado. Se respetaron los principios de transparencia y rigor metodológico establecidos en la Declaración PRISMA 2020.

## Diagrama PRISMA

Gráfico 3. Diagrama PRISMA



Fuente: elaboración propia

## **CAPÍTULO III. ANÁLISIS DE LOS RESULTADOS DE LA INVESTIGACIÓN**

### **3.1. Características generales**

La evidencia analizada se compone de un conjunto heterogéneo de revisiones sistemáticas, revisiones narrativas, metaanálisis, consensos de sociedades científicas, documentos regulatorios y estudios primarios sobre aplicaciones de inteligencia artificial en la interpretación de estudios de imagen médica. En conjunto, estos trabajos describen tanto el rendimiento diagnóstico de los modelos como su impacto en la eficiencia, la organización del trabajo, la percepción profesional y los desafíos éticos y regulatorios asociados (Galarza Medina et al., 2024; Pinto-Coelho, 2023).

En la Tabla 1 se sintetizan las características generales de los documentos incluidos en la revisión, diferenciando el tipo de estudio, las modalidades de imagen abordadas, el contexto asistencial y el dominio principal de aplicación de la inteligencia artificial. Esta síntesis permite visualizar de forma estructurada la heterogeneidad de la evidencia disponible y facilita la interpretación comparada de los resultados.

**Tabla 1.** Características generales de los estudios incluidos en la revisión.

<b>Tipo de documento</b>	<b>Enfoque principal</b>	<b>Modalidades de imagen más frecuentes</b>	<b>Escenario/población predominante</b>	<b>Dominio de IA evaluado</b>
<b>Revisiones sistemáticas y metaanálisis</b>	Rendimiento diagnóstico, exactitud, utilidad clínica	TC, RM, radiografía, mamografía	Pacientes en hospitales terciarios / centros de referencia	Detección y clasificación de hallazgos
<b>Revisiones de alcance</b>	Mapeo de aplicaciones, brechas de evidencia	TC, RM, PET/SPECT, ecografía	Poblaciones mixtas, múltiples sistemas de salud	Panorama global de tareas y flujos de trabajo
<b>Revisiones narrativas / documentos de consenso</b>	Marco conceptual, recomendaciones de práctica	Todas las modalidades	Profesionales de la imagen, servicios de radiología	Integración clínica, gobernanza y ética
<b>Guías y posicionamientos de sociedades científicas</b>	Criterios de implementación y evaluación de IA	Principalmente TC, RM y radiografía	Servicios de radiología y gestión hospitalaria	Criterios de validación y seguimiento
<b>Informes de organismos internacionales y agencias reguladoras</b>	Gobernanza, aspectos regulatorios y de política pública	Modalidades diversas según contexto	Sistemas de salud a nivel nacional o regional	Regulación, equidad y seguridad del paciente

Fuente: elaboración propia

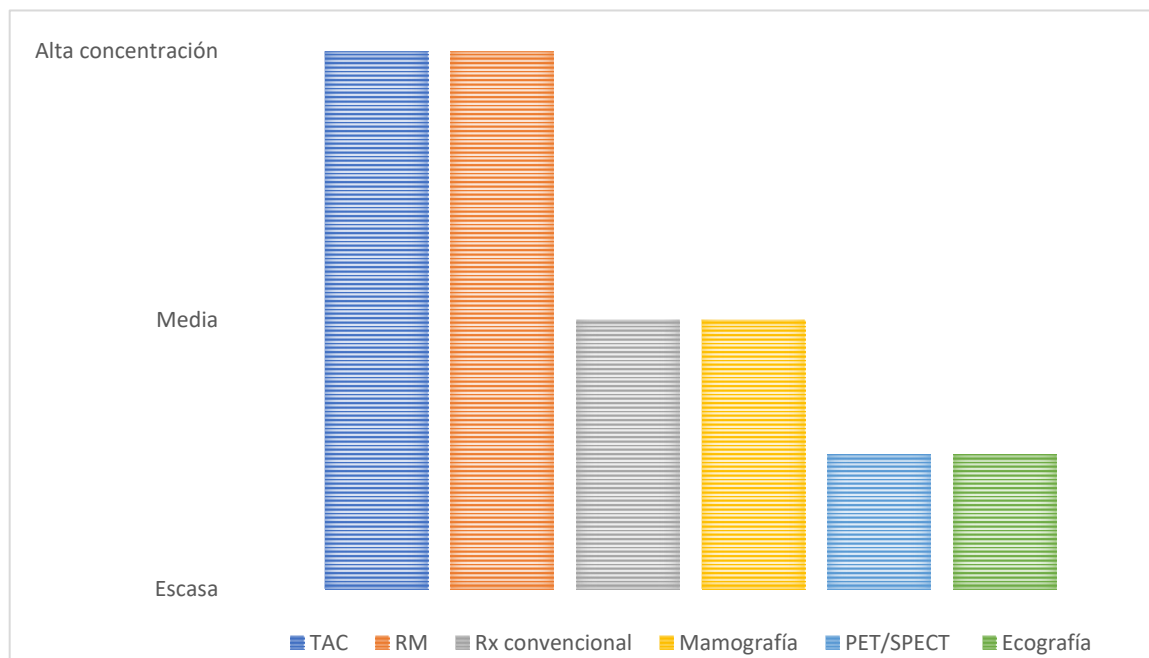
Desde el punto de vista geográfico, la mayoría de los estudios se originan en América del Norte, Europa y Asia oriental, con predominio de Estados Unidos, China y países de Europa occidental (Geis et al., 2019). La evidencia específica procedente de países de ingresos bajos y medios, y en particular de América Latina, es escasa y suele limitarse a experiencias puntuales o a revisiones narrativas; ello plantea dudas sobre la generalización de los resultados a contextos como el latinoamericano (Gómez Rodríguez et al., n.d.; TEMA et al., n.d.).

En cuanto a las modalidades de imagen, las aplicaciones de IA se concentran principalmente en tomografía computarizada (TC) y resonancia magnética (RM), seguidas de radiografía convencional, mamografía, PET/SPECT y ecografía. Las subespecialidades más estudiadas son la neuro imagenología, la imagen torácica y mamaria, así como algunas aplicaciones en radiología oncológica, cardíaca, hepática y musculoesquelética (Eisemann et al., 2025; Shin et al., 2023).

El gráfico 4 sintetiza la distribución de las aplicaciones de IA según modalidad de imagen, seguidas por la Tabla 3, en donde la representación gráfica facilita visualizar el peso relativo de cada modalidad y muestra cómo las líneas de

investigación se han focalizado en escenarios con alto volumen de estudios y potencial impacto clínico.

**Gráfico 4.** Aplicaciones de IA según modalidad de imagen



Fuente: elaboración propia

**Tabla 2.** Modalidades de imagen, subespecialidades y tareas dominantes de la IA.

Modalidad / subespecialidad	Tareas de IA más frecuentes	Ejemplos de aplicaciones clínicas	Comentario sobre el desempeño reportado
<b>TC – neurorradiología</b>	Detección y clasificación de lesiones	Identificación de metástasis cerebrales, accidentes vasculares	Mejora de sensibilidad diagnóstica
<b>TC / radiografía – imagen torácica</b>	Detección de nódulos y patrones intersticiales	Cribado de cáncer de pulmón, neumonía, COVID-19	Reducción de falsos negativos en estudios complejos
<b>Mamografía – mama</b>	Detección y caracterización de lesiones sospechosas	Apoyo al cribado poblacional de cáncer de mama	IA comparable o superior al radiólogo en estudios seleccionados
<b>RM – imagen oncológica y cardiaca</b>	Segmentación y cuantificación	Volumen tumoral, fracción de eyección, realce tardío	Aporta mediciones reproducibles y estandarizadas
<b>PET/SPECT – medicina nuclear</b>	Detección y cuantificación de captaciones patológicas	Evaluación de extensión tumoral, respuesta terapéutica	Mejora la objetividad de la interpretación
<b>Ecografía / musculoesquelético / hepático</b>	Detección y clasificación de lesiones, apoyo a la guía de procedimientos	Lesiones hepáticas focales, masas musculoesqueléticas	Evidencia emergente, aún menos abundante

Fuente: elaboración propia

Las tareas dominantes son la detección y clasificación de hallazgos, la segmentación de órganos y lesiones y, en menor medida, la cuantificación automatizada y el apoyo a la decisión clínica integrada. Los estudios que abordan explícitamente resultados operativos (tiempos de lectura, tiempos puerta-informe, impacto en listas de espera) son considerablemente menos numerosos (Angel & Garrido, n.d.).

### **3.2. Rendimiento diagnóstico y utilidad clínica**

Los resultados de las revisiones y metaanálisis coinciden en que la IA puede alcanzar un rendimiento diagnóstico comparable o superior al de radiólogos en tareas específicas, particularmente cuando se emplea como herramienta de segundo lector o de triage en escenarios de alta prevalencia de hallazgos agudos. En contextos de cribado mamográfico, por ejemplo, el uso de la IA como segundo lector o como lector independiente ha demostrado no inferioridad diagnóstica, con potencial reducción de la doble lectura humana. Sin embargo, persiste una variabilidad significativa entre entornos, proveedores y poblaciones, lo que obliga a validar localmente el rendimiento antes de su adopción rutinaria (Dikici et al., 2020; Ennab & Mcheick, 2024; Koçak et al., 2025; Lång et al., 2023; Nagendran et al., 2020).

La literatura de implementación muestra de forma consistente que la “combinación óptima” radiólogo + IA supera a cualquiera de los dos por separado (Chen et al., 2024). La sensibilidad tiende a incrementarse cuando la salida del algoritmo se integra de manera no intrusiva en la interfaz de reporte y cuando los profesionales reciben formación explícita sobre los puntos ciegos del modelo (densidades particulares, artefactos, morfologías atípicas) (Brady et al., 2024; Iglesias López, n.d.-a). Las mejoras son más notables en tareas con alta relación señal-ruido, como la detección de hemorragia intracraneal en TC, y menos estables en patrones sutiles o multimorfológicos, como nódulos pulmonares pequeños en radiografía (Han et al., 2024).

Para facilitar la lectura comparada de los resultados, la Tabla 4 resume de manera cualitativa el impacto de la IA sobre el rendimiento diagnóstico en los principales

dominios clínicos identificados, diferenciando los desenlaces analizados y la dirección del efecto respecto a la interpretación convencional.

**Tabla 3.** Síntesis cualitativa del impacto de la IA sobre el rendimiento diagnóstico

<b>Dominio clínico / aplicación</b>	<b>Desenlace principal evaluado</b>	<b>Comparación con la interpretación estándar</b>	<b>Comentario cualitativo</b>
Detección de hallazgos focales (nódulos pulmonares, lesiones mamarias, etc.)	Sensibilidad, especificidad, AUC	IA sola y IA + radiólogo suelen superar al radiólogo solo en sensibilidad	Riesgo de aumento de falsos positivos en algunos escenarios
Clasificación de lesiones / estratificación de riesgo	AUC, exactitud global	Mejoras moderadas o equivalentes a expertos humanos	Potencial para apoyar decisiones de manejo
Segmentación y cuantificación de estructuras	Reproducibilidad, concordancia inter observador	IA ofrece mayor consistencia que lecturas manuales	Útil para seguimiento longitudinal y planificación
Integración multimodal (imagen + datos clínicos)	Modelos de predicción de pronóstico o respuesta terapéutica	IA tiende a superar modelos clínicos tradicionales	Evidencia aún limitada y heterogénea


Fuente: elaboración propia

En estudios observacionales y análisis agregados, la incorporación de IA en la práctica clínica real se asocia a una mejoría moderada del rendimiento diagnóstico combinado respecto del estándar humano sin IA. Este efecto es heterogéneo según la modalidad y la tarea analizada, y suele ser mayor cuando la IA actúa como segundo lector o como herramienta de triage que reorganiza colas de lectura, priorizando estudios con hallazgos potencialmente graves (Dikici et al., 2020; Gonçalves et al., 2024; Kohli et al., 2017; Obuchowicz et al., 2025).

No obstante, la utilidad clínica no puede inferirse únicamente a partir de métricas como el área bajo la curva (AUC) o la sensibilidad. Buena parte de la literatura se centra en desenlaces intermedios, sin demostrar de manera sistemática el impacto sobre resultados clínicos claros (mortalidad, discapacidad, tiempo hasta el tratamiento, eventos cardiovasculares). Las revisiones analizadas subrayan que el valor real de la IA depende de su capacidad para modificar decisiones terapéuticas en pacientes reales con un beneficio neto y sin daño añadido (Gómez Rodríguez et al., n.d.; Han et al., 2024; Krishna NK et al., 2025; Muhammad & Bendeche, 2024b; Stogiannos et al., 2025).

### 3.3. Impacto en la eficiencia y el flujo de trabajo

**Gráfico 5.** Impacto de la IA en indicadores de eficiencia y flujo de trabajo



Fuente: elaboración propia

El análisis de los estudios que evalúan la eficiencia y la organización del trabajo revela resultados más matizados que los observados en el rendimiento diagnóstico. Un metaanálisis reporta que la asistencia concurrente de IA puede reducir el tiempo de lectura aproximadamente en una cuarta parte (en torno a un 27 % de reducción media), y que el volumen de estudios que requieren lectura humana disminuye casi a la mitad cuando la IA se utiliza como segundo lector y en más de un 60 % cuando actúa como herramienta de screening para descartar estudios aparentemente normales(Ennab & Mcheick, 2024; Wenderott et al., 2024).

Sin embargo, una revisión sistemática y metaanálisis centrada en desenlaces operativos concluye que, pese a que alrededor del 67 % de los estudios individuales describen reducciones de tiempo, el análisis conjunto no permite demostrar de forma robusta un impacto global estadísticamente significativo sobre el tiempo total dedicado a tareas de imagen(Nagendran et al., 2020). En algunos contextos, la introducción de IA incrementa temporalmente la carga de trabajo, al exigir revisión de falsos positivos, gestión de discrepancias entre la sugerencia algorítmica y la interpretación humana, o adaptación de nuevos flujos de trabajo(Dikici et al., 2020).

Más allá de los tiempos de lectura, los indicadores de eficiencia como la gestión de listas de espera, el tiempo puerta-informe, la reasignación de tareas dentro del equipo radiológico o el impacto sobre el burnout han sido poco explorados y con resultados heterogéneos(Liu et al., 2024). La literatura de implementación sugiere que la IA aporta más valor cuando: transforma un cuello de botella operativo en una secuencia paralela (la activación rápida de códigos de intervención) o proporciona cuantificaciones estables que orientan la conducta clínica(Iglesias López, n.d.-b).

Al mismo tiempo, se describen “efectos boomerang” cuando las interfaces generan sobrecarga de alertas, distracciones o sesgos de anclaje, lo que puede anular las ventajas esperadas. Esto conduce a recomendaciones específicas de diseño centrado en el usuario, limitación de alarmas irrelevantes y comunicación explícita de la incertidumbre algorítmica(Muhammad & Bendeche, 2024b).

### **3.4. Calidad metodológica, sesgos y generalización de los modelos**

La evaluación de la calidad metodológica de los estudios de IA en imagen médica muestra limitaciones recurrentes. Predominan diseños retrospectivos, unicéntricos, con tamaños muestrales moderados y validación interna exclusiva o mayoritaria. En muchos trabajos, los conjuntos de entrenamiento y de validación proceden de la misma institución o de cohortes muy similares, lo que favorece el sobreajuste y reduce la capacidad de generalizar los resultados a otros entornos(Bahakeem et al., 2023; Eisemann et al., 2025; Han et al., 2024; Lång et al., 2023; Yaynishet et al., 2024).

La Tabla 5 resume las principales fuentes de sesgo y limitaciones metodológicas identificadas en los estudios incluidos, así como sus implicaciones potenciales para la generalización de los modelos y para su uso seguro en la práctica clínica.

**Tabla 4.** Principales fuentes de sesgo y limitaciones metodológicas en los estudios de IA en imagen médica

<b>Dimensión metodológica</b>	<b>Problema identificado</b>	<b>Implicación para la práctica clínica</b>
<b>Población de estudio</b>	Muestras poco diversas (por edad, sexo, etnia, nivel socioeconómico)	Riesgo de menor desempeño en poblaciones distintas de las de entrenamiento
<b>Validación externa</b>	Ausencia o validación externa limitada a uno o pocos centros	Dificultad para extrapolar resultados a otros entornos
<b>Tamaño muestral y selección de casos</b>	Tamaños pequeños, casos seleccionados o altamente prevalentes	Sobreestimación del rendimiento en condiciones ideales
<b>Definición de desenlaces y estándar de referencia</b>	Estándares de referencia imperfectos o no claramente descritos	Incertidumbre sobre la "verdad" frente a la cual se calibra el modelo
<b>Reporte de métricas</b>	Falta de intervalos de confianza y análisis por subgrupos	Imposibilidad de evaluar precisión y equidad del modelo
<b>Transparencia del modelo</b>	Descripción incompleta de la arquitectura, entrenamiento y actualización	Dificultad para evaluar riesgos, reproducir resultados y supervisar el desempeño

Fuente: elaboración propia

El uso insuficiente de validación externa robusta se refleja en caídas de rendimiento clínicamente relevantes cuando los algoritmos se aplican a datos "no vistos". La revisión RAISE documenta una disminución media cercana al 6 % en métricas de desempeño al aplicar los modelos a datos externos, mientras que otros análisis informan reducciones de hasta el 24 %, especialmente en contextos con prevalencias distintas, protocolos de adquisición variables o características demográficas diferentes (Kelly et al., 2022).

Las fuentes de sesgo identificadas incluyen la falta de diversidad demográfica y técnica en los *datasets*, el muestreo no representativo, la escasa compartición de conjuntos de datos de referencia (menos del 6 % de los artículos en revistas de radiología comparten total o parcialmente sus datos experimentales) y la ausencia de análisis de subgrupos. Estas limitaciones dificultan la reproducibilidad, la auditoría independiente y la evaluación de la equidad del desempeño en diferentes poblaciones (Kelly et al., 2022).

Además, es frecuente la presentación de métricas sin intervalos de confianza, la falta de evaluación del impacto clínico y la omisión de análisis detallados de falsos positivos y falsos negativos por paciente, especialmente relevante en tareas de detección multilesión. Las guías metodológicas (CONSORT-AI, CLAIM) son citadas como referentes para mejorar la transparencia, pero su adopción en la literatura revisada aún es incompleta (Nagendran et al., 2020).

## **Explicabilidad, transparencia y riesgo de caja negra**

La explicabilidad emerge como un elemento central para la aceptabilidad clínica de la IA en imagen médica. Las revisiones sobre técnicas de IA explicable (XAI) señalan que muchas de las herramientas disponibles (como los mapas de atención o ciertas aproximaciones generativas jerárquicas) ofrecen explicaciones parciales y, en ocasiones, inconsistentes con los procesos fisiopatológicos conocidos. En consecuencia, se insiste en que estas salidas deben interpretarse como ayudas visuales y no como pruebas concluyentes del mecanismo subyacente(Champendal et al., 2023).

De forma reiterada, los documentos de consenso describen a los sistemas de aprendizaje profundo como cajas negras, en las que los profesionales tienen poca o ninguna visibilidad de cómo el algoritmo llega a su conclusión. Esta opacidad se traduce en dos peligros principales: la automatización acrítica de decisiones y la erosión de la autonomía profesional. Sin información clara sobre capacidades, límites y condiciones de validez, la toma de decisiones clínicas puede verse comprometida(Muhammad & Bendeche, 2024b).

Las recomendaciones para mitigar estos riesgos incluyen la elaboración de “*model cards*” y documentación técnica accesible, la adhesión estricta a guías como CONSORT-AI y CLAIM, la implementación de procesos estandarizados de prueba antes del despliegue y la vigilancia posmercado con mecanismos de reporte de incidentes y capacidad de “*rollback*” cuando se detecta degradación del desempeño (*drift*)(Nagendran et al., 2020).

La transparencia se concibe de manera amplia: no solo implica describir la arquitectura del modelo, sino informar a los centros sanitarios y, cuando corresponda, a los pacientes sobre las condiciones de uso, los niveles esperados de exactitud, las limitaciones conocidas y los grupos en los que el rendimiento podría ser inferior. Esta transparencia proporcional al riesgo se plantea como condición de legitimidad clínica y social(Bhandari, n.d.).

## **Percepción, aceptación y necesidades formativas**

Las encuestas a radiólogos y otros profesionales de la imagen muestran una aceptación condicionada de la IA. En general, la IA se percibe como un

complemento al trabajo del radiólogo, con potencial para mejorar la eficiencia y la detección de hallazgos, pero no como un sustituto del juicio clínico humano. Muchos profesionales anticipan cambios en el perfil de la especialidad (con énfasis más clínico o técnico según subgrupos), pero no prevén una reducción drástica de plazas laborales en el corto plazo(D'antonoli, 2020; Neri et al., 2019).

Un hallazgo consistente es la resistencia para aceptar informes generados exclusivamente por IA: una proporción considerable de radiólogos considera que los pacientes no los aceptarían y que la relación equipo radiológico–paciente no debería medirse únicamente por sistemas automatizados. Entre los pacientes, los estudios disponibles indican una preferencia por decisiones supervisadas por médicos, con la IA en un rol complementario; la confianza aumenta cuando se garantiza que la responsabilidad última recae en el profesional humano(Becker et al., 2022).

En estudiantes de Medicina y residentes de radiología, las actitudes tienden a ser más favorables hacia la IA como herramienta de apoyo, pero se identifican lagunas importantes de conocimiento en fundamentos de IA, análisis de datos y lectura crítica de estudios. Esta brecha formativa ha motivado recomendaciones para incorporar contenidos de IA, ética de datos y radiología digital en los planes de estudio, tanto de grado como de posgrado(Zanardo et al., 2024).

Además, se describe una relación compleja entre uso de IA, carga laboral y burnout. Algunos estudios sugieren que, si la IA se implementa como una capa adicional de tareas sin rediseñar el flujo de trabajo, puede agravar la presión asistencial. Por el contrario, cuando se integra de forma estratégica para aliviar tareas repetitivas y apoyar la priorización de estudios críticos, puede contribuir a reducir el agotamiento profesional(Chen et al., 2024; Liu et al., 2024).

### **Aspectos éticos, regulatorios y de gobernanza**

Los documentos éticos multisocietarios y las guías internacionales coinciden en que el uso de IA en imagen médica debe promover el bienestar, minimizar el daño y distribuir de forma justa beneficios y riesgos, respetando la dignidad, la privacidad y los derechos de los pacientes. La responsabilidad clínica permanece en el profesional humano y en la institución sanitaria, no en la herramienta tecnológica,

y la supervisión humana significativa se considera irrenunciable (Aldhafeeri, 2025; Geis et al., 2019; Herington et al., 2023).

La guía de la OMS sobre modelos de lenguaje de gran tamaño (LMM) en salud amplía el análisis a sistemas de propósito general que pueden intervenir en múltiples tareas (interpretación de imágenes, generación de informes, apoyo educativo). Este documento subraya riesgos a nivel de sistemas de salud (dependencia tecnológica, sobreestimación de beneficios, impacto laboral, ciberseguridad), de cumplimiento regulatorio (protección de datos, derechos humanos, responsabilidad) y sociales (concentración de poder en grandes corporaciones, huella ambiental) (World Health Organization (WHO), 2024).

En el contexto europeo, la implementación del AI Act sitúa a muchas aplicaciones de IA en radiología como sistemas de “alto riesgo”, sujetos a requisitos estrictos de gestión de riesgos, calidad de datos, documentación técnica, transparencia, supervisión humana y monitorización posdespliegue. Las sociedades radiológicas recomiendan que los servicios de imagen se involucren de forma activa en la definición de estándares técnicos y clínicos, y que negocien contratos que contemplen actualización, soporte y retirada segura de sistemas obsoletos (Kotter et al., 2025; Neri et al., 2019).

Los textos de ética y gobernanza analizados llaman la atención sobre el sesgo algorítmico y la equidad. Los *datasets* de imagen suelen subrepresentar a poblaciones vulnerables, lo que puede traducirse en peores resultados para determinados grupos (minorías étnicas, pacientes de bajos recursos, regiones con menos infraestructura). Aunque la evidencia cuantitativa específica en radiología aún es limitada, el problema se reconoce como prioritario en la agenda de investigación y regulación (Brady et al., 2024; Galarza Medina et al., 2024; Kocak et al., 2025).

### **Desafíos de implementación en la práctica clínica real**

La transición desde modelos desarrollados en entornos de investigación a su uso en contextos clínicos reales constituye uno de los desafíos más señalados. Los errores de implementación descritos incluyen: desajuste entre el caso de uso para el que fue entrenado el modelo y el contexto en que se despliega; falta de

representatividad de los datos de entrenamiento; integración deficiente con los sistemas de información radiológica (PACS/RIS); ausencia de protocolos claros para la validación local y la monitorización continua; y carencias en la formación de los usuarios(Shin et al., 2023; Wenderott et al., 2024).

Ejemplos documentados muestran que modelos con desempeño excelente en publicaciones iniciales pueden fracasar al enfrentarse a poblaciones con distinta prevalencia de enfermedad, patrones patológicos variados o cambios en los protocolos de adquisición. La falta de mecanismos de reentrenamiento y revalidación sistemática ante el “*drift*” de datos y modelos compromete la seguridad y la eficacia a largo plazo(Koçak et al., 2025).

Desde la perspectiva de la infraestructura técnica, se describen problemas de conectividad, interoperabilidad (estándares DICOM, HL7), capacidad de procesamiento y almacenamiento, y vulnerabilidades de ciberseguridad. Cuando los sistemas de IA no se integran de forma fluida en el ecosistema digital existente, pueden generarse cuellos de botella adicionales, duplicidad de trabajo y aumento de riesgos de seguridad(Dikici et al., 2020).

En el ámbito de los factores humanos, la resistencia al cambio, la desconfianza o, en el extremo opuesto, la sobreconfianza en las salidas algorítmicas (“*automation bias*”, “*anchoring*”) pueden conducir a errores clínicos, infrautilización de herramientas potencialmente útiles o gastos injustificados. De ahí que las recomendaciones insistan en invertir en alfabetización en IA para radiólogos, técnicos y gestores, involucrar a los usuarios desde las fases de diseño y garantizar modelos de supervisión humana significativa(Dikici et al., 2020; Neri et al., 2019).

Las guías prácticas sobre desarrollo, adquisición, implementación y monitorización de herramientas de IA proponen abordar todo el ciclo de vida del sistema, desde la identificación de la necesidad clínica y la evaluación de la evidencia, hasta la monitorización de desempeño, seguridad y satisfacción de usuarios, incluyendo planes de desmantelamiento cuando el modelo se vuelva obsoleto o inseguro(Galarza Medina et al., 2024; Koçak et al., 2025).

## **Vacíos de evidencia y retos en contextos de ingresos bajos y medios**

Un hallazgo consistente es la asimetría geográfica de la evidencia. Los estudios de alta calidad se concentran en centros académicos de alto volumen de países de altos ingresos, mientras que los contextos de bajos y medianos ingresos están pobremente representados. Las revisiones narrativas en español subrayan que, en regiones como América Latina, la experiencia con IA en imagen médica se basa más en reportes puntuales y series de casos que en evaluaciones sistemáticas de desempeño o impacto (Iglesias López, n.d.-b; Lanzagorta-Ortega et al., 2022; Stogiannos et al., 2025).

Esta brecha plantea interrogantes sobre la aplicabilidad de los modelos entrenados en poblaciones y sistemas de salud muy distintos. Factores como la infraestructura tecnológica limitada, la fragmentación de los sistemas de información, la escasez de datos locales de alta calidad y la falta de marcos regulatorios consolidados pueden dificultar aún más la implementación responsable de IA en estos entornos. Existe además el riesgo de que la introducción no planificada de IA amplifique desigualdades, beneficiando principalmente a centros con mayores recursos y dejando rezagadas a poblaciones vulnerables (INTELIGÊNCIA ARTIFICIAL EM IMAGENS MÉDICAS: IMPACTOS E DESAFIOS Artificial Intelligence in Medical Imaging: Impacts and Challenges, n.d.).

## **Síntesis integradora frente a la pregunta de investigación**

En conjunto, los resultados analizados permiten extraer varias conclusiones centrales en relación con la pregunta de investigación sobre las aplicaciones de la IA en la interpretación de estudios de imagen médica:

- 1. La IA se ha consolidado como una herramienta diagnóstica valiosa en tareas específicas**, con especial solidez en escenarios de cribado y detección de hallazgos frecuentes o agudos. No obstante, su rol debe entenderse como complementario y no sustitutivo del juicio radiológico, siendo la dupla radiólogo + IA la que ofrece, de forma más consistente, el mejor rendimiento (Chen et al., 2024; Rojas, 2020).
- 2. El impacto sobre la eficiencia y la carga de trabajo es real pero heterogéneo.** Existen evidencias de reducciones en tiempos de lectura y

reorganización más eficiente de colas, pero el beneficio global depende menos de la sofisticación técnica del modelo que de la calidad del diseño organizativo, la integración tecnológica y la gobernanza institucional(Iglesias López, n.d.-b; Liu et al., 2024; Obuchowicz et al., 2025; Shin et al., 2023).

- 3. La calidad metodológica y la generalización de los modelos representan un límite importante.** La predominancia de estudios retrospectivos, unicéntricos y con validación interna, junto con caídas de rendimiento al pasar a datos externos, obliga a interpretar con cautela los resultados y a exigir evaluaciones robustas antes del despliegue clínico(Dikici et al., 2020; Kelly et al., 2022).
- 4. La explicabilidad, la transparencia y la equidad son condiciones indispensables para la legitimidad clínica y social de la IA.** No basta con incorporar mapas de calor o salidas visuales; se requieren marcos de gobernanza que aseguren documentación clara, evaluación continua, comunicación honesta de capacidades y limitaciones y análisis explícitos del desempeño en grupos potencialmente vulnerables(Champendal et al., 2023; Muhammad & Bendeche, 2024b).
- 5. La aceptación social y profesional está condicionada por la percepción de beneficio real y por la claridad en la distribución de responsabilidades.** Los profesionales aceptan mejor la IA cuando se la presenta como “colega digital” supervisado; los pacientes prefieren decisiones en las que el médico mantiene la responsabilidad última(Bahakeem et al., 2023; Neri et al., 2019; Zanardo et al., 2024).
- 6. Persisten vacíos significativos de evidencia,** especialmente en contextos latinoamericanos y otros sistemas de salud con recursos limitados, en estudios prospectivos y ensayos que midan resultados clínicos y económicos, y en evaluaciones sistemáticas de equidad(Galarza Medina et al., 2024; Moraes et al., 2023; TEmA et al., n.d.).

A partir de estos hallazgos, se identifican como líneas prioritarias para la investigación futura: el diseño de estudios prospectivos y ensayos controlados que evalúen el impacto de la IA sobre desenlaces clínicos y organizativos; el desarrollo

y validación de modelos en poblaciones y entornos subrepresentados; la integración rutinaria de métricas de equidad y explicabilidad en la evaluación de modelos; el fortalecimiento de la formación en IA para estudiantes y profesionales de la salud; y la construcción de marcos regulatorios y de gobernanza adaptados a las realidades regionales. De esta manera, la IA en imagen médica podrá avanzar desde resultados prometedores en entornos controlados hacia un despliegue clínico responsable, equitativo y alineado con los principios de la medicina basada en evidencia(*INTELIGÊNCIA ARTIFICIAL NA INTERPRETAÇÃO DE EXAMES RADIOLÓGICOS – ISSN 1678-0817 Qualis B2*, n.d.; Kelly et al., 2022; Waller et al., 2022).

## CONCLUSIONES

- La evidencia revisada muestra que la aplicación de inteligencia artificial (IA) en la interpretación de estudios de imagen médica constituye un avance sólido, aunque todavía incompleto, dentro del diagnóstico por imagen. Los algoritmos basados en aprendizaje automático y aprendizaje profundo han demostrado mejoras consistentes en tareas específicas de detección, clasificación y segmentación, sobre todo en modalidades como tomografía computarizada, resonancia magnética, radiografía y mamografía. En múltiples escenarios, el rendimiento de la IA alcanza niveles comparables o superiores al del radiólogo cuando se utiliza como segundo lector o herramienta de triage, lo que coincide con los resultados reportados por revisiones y metaanálisis recientes. No obstante, persiste una marcada heterogeneidad en la calidad metodológica, el diseño de los estudios y los contextos de aplicación, lo que obliga a interpretar los hallazgos con cautela.
- En términos de precisión diagnóstica, la integración radiólogo + IA se consolida como el enfoque más robusto. La combinación permite incrementar la sensibilidad en tareas críticas, como la detección de hemorragia intracraneal o de lesiones mamarias, y mejora la reproducibilidad en procesos de segmentación y cuantificación de estructuras. De forma general, la IA aporta mayor valor en problemas de alto volumen y patrones bien definidos, mientras que su desempeño es menos estable ante variabilidad anatómica, artefactos o patrones sutiles. Estas variaciones ponen de relieve la necesidad de validación externa y local antes de la adopción rutinaria, dado que los modelos tienden a perder rendimiento al aplicarse a poblaciones distintas de aquellas con las que fueron entrenados, fenómeno ampliamente documentado en la literatura analizada y que limita la generalización de los resultados.

- En la eficiencia operativa, los hallazgos son prometedores pero heterogéneos. Varios estudios describen reducciones en el tiempo de lectura, mejoras en la priorización de casos urgentes y apoyo efectivo en la organización del flujo de trabajo cuando la IA se integra de forma adecuada en los sistemas de información. Sin embargo, otros trabajos muestran beneficios más modestos o incluso incrementos temporales de carga debido a falsos positivos, ajustes de interfaces, necesidad de verificación humana y etapas de adaptación del equipo clínico. El impacto final depende menos de la sofisticación técnica del algoritmo y más de la calidad de la integración organizativa y tecnológica. Ello confirma que la IA no es una solución automática, sino una herramienta cuyo valor real emerge cuando se implementa de manera estratégica, con procesos claros, capacitación adecuada y estructuras de gobernanza bien definidas.
- Las limitaciones metodológicas de los estudios incluidos muestran un patrón que debe considerarse de forma prioritaria. Predominan diseños retrospectivos, validaciones internas y muestras poco diversas, lo que restringe la extrapolación de los resultados y aumenta el riesgo de sesgos. La ausencia frecuente de intervalos de confianza, análisis por subgrupos, métricas de calibración y evaluaciones de impacto clínico dificulta la valoración completa del desempeño real de estos sistemas en la práctica cotidiana. Esta revisión refuerza la necesidad de estudios prospectivos, multicéntricos, con validación externa rigurosa y desenlaces clínicamente relevantes, tal como señalan las guías metodológicas internacionales para la evaluación de modelos predictivos y sistemas basados en IA.
- Las implicaciones éticas, legales y regulatorias se configuran como ejes centrales para la adopción responsable de estas tecnologías. La opacidad de muchos modelos, la limitada explicabilidad y el riesgo de automatización acrítica representan amenazas concretas para la seguridad del paciente y la autonomía profesional. Los marcos de gobernanza propuestos por organismos internacionales, junto con normativas emergentes, reconocen a estos sistemas como tecnologías de alto riesgo y exigen transparencia,

supervisión humana significativa, documentación exhaustiva de datos y modelos, así como control posdespliegue. La equidad se erige como una preocupación transversal: bases de datos poco representativas pueden amplificar desigualdades preexistentes en salud, afectando de manera desproporcionada a poblaciones vulnerables. Estas consideraciones éticas refuerzan la necesidad de una adopción prudente, contextualizada y acompañada de formación específica en IA para radiólogos, clínicos y gestores.

- En el ámbito latinoamericano, y específicamente en Ecuador, la evidencia identificada sigue siendo escasa y fragmentada. La mayor parte de los estudios relevantes proviene de centros de altos ingresos, lo que dificulta extrapolar los resultados a sistemas con limitaciones tecnológicas, organizativas y de recursos humanos. Aunque se reconocen iniciativas locales incipientes, persisten brechas en formación especializada, infraestructura digital, marcos regulatorios y disponibilidad de bases de datos de calidad. Esto demanda estrategias de investigación y políticas públicas adaptadas a las realidades regionales, incluyendo la construcción de repositorios de imagen propios, el fortalecimiento de capacidades técnicas y la elaboración de lineamientos nacionales que orienten la evaluación, validación e implementación de la IA en imagenología.

En conjunto, los hallazgos permiten afirmar que la IA tiene un potencial real para mejorar la precisión diagnóstica, reducir tiempos de análisis y apoyar la toma de decisiones clínicas en la interpretación de estudios de imagen médica. Sin embargo, su aporte efectivo depende de tres condiciones esenciales y estrechamente interrelacionadas: la calidad metodológica y la validación externa de los modelos; la integración cuidadosa y evaluada en el flujo de trabajo clínico y organizativo; y la existencia de una gobernanza ética y regulatoria sólida que garantice transparencia, seguridad, equidad y supervisión humana significativa. En este escenario, la IA no sustituye al radiólogo, sino que lo complementa, siempre que su diseño, implementación y monitorización se alineen con los principios de buena práctica clínica y con las necesidades reales de los sistemas de salud en los que se inserta.

## RECOMENDACIONES

- Para comprender el verdadero alcance de la IA en la reducción de errores diagnósticos, la mejora de la oportunidad terapéutica o la optimización de la atención, se requieren estudios diseñados específicamente para medir estos resultados en pacientes reales. Este tipo de investigación también ayudaría a determinar si las mejoras en sensibilidad o especificidad se traducen en beneficios tangibles para los sistemas de salud.
- Asimismo, es fundamental ampliar la validación externa de los modelos en poblaciones, instituciones y sistemas de salud subrepresentados. Este desafío es especialmente relevante en regiones como América Latina, donde existen variaciones en epidemiología, protocolos de adquisición, disponibilidad tecnológica y perfiles demográficos. Validar los modelos en estos entornos no solo determina su aplicabilidad real, sino que también permite identificar ajustes necesarios antes de su adopción.
- Otra recomendación clave es incorporar de forma sistemática métricas de equidad, explicabilidad y análisis por subgrupos en la evaluación de modelos. La falta de diversidad en los conjuntos de datos y la ausencia de desgloses por edad, sexo, etnia o tipo de institución dificultan evaluar si la IA funciona de manera justa y consistente. Del mismo modo, la explicabilidad debe dejar de ser un añadido opcional y convertirse en una exigencia metodológica. Modelos más transparentes mejoran la aceptación profesional, permiten auditorías más rigurosas y reducen riesgos de automatización acrítica. Evaluar explícitamente el comportamiento del algoritmo en poblaciones vulnerables también es esencial para evitar la amplificación de desigualdades en salud.

- Es igualmente importante fortalecer la formación en inteligencia artificial dirigida a radiólogos, técnicos, clínicos y gestores. La evidencia analizada muestra que las actitudes hacia la IA son más favorables cuando los profesionales entienden sus capacidades y limitaciones. La alfabetización digital no solo reduce temores y resistencias, sino que facilita un uso más seguro y crítico de las herramientas. Incluir contenidos de IA, ética de datos y gobernanza tecnológica en los programas de grado y posgrado es una estrategia que puede preparar a una nueva generación de profesionales capaces de interactuar con estos sistemas de forma responsable.
- Otra necesidad urgente es el desarrollo de marcos regulatorios nacionales y guías institucionales adaptadas a los contextos locales. Dado que muchas de las aplicaciones de IA en imagen médica se consideran de alto riesgo, los países deben establecer procesos claros para evaluación, adquisición, despliegue y monitorización continua. Estos marcos deben contemplar supervisión humana significativa, requisitos de transparencia, protocolos de seguridad y mecanismos para retirar modelos cuando su desempeño se degrade. Una regulación clara no solo protege a los pacientes, sino que también otorga seguridad jurídica a los centros de salud que incorporan estas herramientas.
- Finalmente, se recomienda invertir en infraestructura digital y fomentar la creación de repositorios de datos de calidad que puedan alimentar modelos adaptados a las necesidades regionales. La falta de bases de datos representativas limita la investigación y aumenta la dependencia de tecnologías desarrolladas en otras realidades. Construir repositorios propios, con criterios de calidad, privacidad y estandarización, permitiría entrenar modelos más robustos y alineados con las características clínicas y demográficas locales. Esta inversión también sentaría las bases para colaboraciones multicéntricas y para avanzar hacia una adopción de IA más equitativa y sostenible.

## ¿Qué se necesita aquí en Ecuador?

- Hablamos de Marco regulatorio y gobernanza institucional. Aunque el AI Act europeo no aplica localmente, sus recomendaciones operativas son transferibles: clasificación por riesgo, supervisión humana obligatoria, pruebas estandarizadas previas al despliegue y vigilancia posmercado con intercambio de señales entre centros. Cada institución debería formalizar un comité de IA que defina casos de uso prioritarios, métricas de seguridad y utilidad, y protocolos de actualización.
- Es clave construir repositorios curados representativos de la casuística ecuatoriana, con acuerdos de gobernanza y anonimización, para validación local y detección de *drift*. La baja compartición internacional de datos refuerza la necesidad de cohortes propias y de alianzas con redes regionales.
- Invertir en integración PACS con canales de triage y retroalimentación, y en formación continua del personal sobre modos de uso, métricas operativas y sesgos de interacción, para maximizar el beneficio clínico y minimizar el riesgo de automatización acrítica.
- Adoptar políticas de transparencia equivalentes a las propuestas internacionales: informar a clínicos y pacientes sobre capacidades, límites y uso de IA; documentar PPV/NPV visibles; y establecer vías simples para reportar fallos. Como recuerda la literatura: “Es importante asegurar que la tecnología promueva el bienestar, minimice el daño y distribuya justamente beneficios y daños entre todas las partes interesadas”.

## BIBLIOGRAFÍA

- Aldhafeeri, F. M. (2025). Governing Artificial Intelligence in Radiology: A Systematic Review of Ethical, Legal, and Regulatory Frameworks. *Diagnostics*, 15(18), 2300. <https://doi.org/10.3390/diagnostics15182300>
- Anderson, A., Marinovich, M., Houssami, N., Lowry, K., Elmore, J., Buist, D., Hofvind, S., & Lee, C. (2022). Independent External Validation of Artificial Intelligence Algorithms for Automated Interpretation of Screening Mammography: A Systematic Review. *Journal of the American College of Radiology: JACR*. <https://doi.org/10.1016/j.jacr.2021.11.008>
- Angel, M., & Garrido, A. (n.d.). *Uso de la inteligencia artificial en el diagnóstico imagenológico Artificial intelligence use in imaging diagnosis*. Retrieved <https://orcid.org/0000-0002-0532-9273>
- Azizi, A., Azizi, M., & Nasri, M. (2023). Artificial Intelligence Techniques in Medical Imaging: A Systematic Review. *International Journal of Online and Biomedical Engineering*, 19(17), 66–97. <https://doi.org/10.3991/ijoe.v19i17.42431>
- Bahakeem, B. H., Alobaidi, S. F., Alzahrani, A. S., Alhasawi, R., Alzahrani, A., Alqahtani, W., Alhashmi Alamer, L., Bin Laswad, B. M., & Al Shanbari, N. (2023). The General Population's Perspectives on Implementation of Artificial Intelligence in Radiology in the Western Region of Saudi Arabia. *Cureus*. <https://doi.org/10.7759/cureus.37391>
- Becker, C. D., Kotter, E., Fournier, L., & Martí-Bonmatí, L. (2022). Current practical experience with artificial intelligence in clinical radiology: a survey of the European Society of Radiology. *Insights into Imaging*, 13(1). <https://doi.org/10.1186/s13244-022-01247-y>

Bhandari, A. (n.d.). *Revolutionizing Radiology with Artificial Intelligence*.

Brady, A. P., Allen, B., Chong, J., Kotter, E., Kottler, N., Mongan, J., Oakden-Rayner, L., dos Santos, D. P., Tang, A., Wald, C., & Slavotinek, J. (2024). Developing, purchasing, implementing and monitoring AI tools in radiology: practical considerations. A multi-society statement from the ACR, CAR, ESR, RANZCR & RSNA. *Insights into Imaging*, 15(1). <https://doi.org/10.1186/s13244-023-01541-3>

Champendal, M., Müller, H., Prior, J. O., & dos Reis, C. S. (2023). A scoping review of interpretability and explainability concerning artificial intelligence methods in medical imaging. In *European Journal of Radiology* (Vol. 169). Elsevier Ireland Ltd. <https://doi.org/10.1016/j.ejrad.2023.111159>

Chen, M., Wang, Y., Wang, Q., Shi, J., Wang, H., Ye, Z., Xue, P., & Qiao, Y. (2024). Impact of human and artificial intelligence collaboration on workload reduction in medical image interpretation. *Npj Digital Medicine*, 7(1). <https://doi.org/10.1038/s41746-024-01328-w>

D'antonoli, T. A. (2020). Ethical considerations for artificial intelligence: An overview of the current radiology landscape. *Diagnostic and Interventional Radiology*, 26(5), 504–511. <https://doi.org/10.5152/dir.2020.19279>

De Vries, B. M., Zwezerijnen, G. J. C., Burchell, G. L., van Velden, F. H. P., Menke-van der Houven van Oordt, C. W., & Boellaard, R. (2023). Explainable artificial intelligence (XAI) in radiology and nuclear medicine: a literature review. In *Frontiers in Medicine* (Vol. 10). Frontiers Media SA. <https://doi.org/10.3389/fmed.2023.1180773>

Dikici, E., Bigelow, M., Prevedello, L. M., White, R. D., & Erdal, B. S. (2020). Integrating AI into radiology workflow: levels of research, production, and feedback maturity. *Journal of Medical Imaging*, 7(01), 1. <https://doi.org/10.1117/1.jmi.7.1.016502>

- Eisemann, N., Bunk, S., Mukama, T., Baltus, H., Elsner, S. A., Gomille, T., Hecht, G., Heywang-Köbrunner, S., Rathmann, R., Siegmann-Luz, K., Töllner, T., Vomweg, T. W., Leibig, C., & Katalinic, A. (2025). Nationwide real-world implementation of AI for cancer detection in population-based mammography screening. *Nature Medicine*, 31(3), 917–924. <https://doi.org/10.1038/s41591-024-03408-6>
- Ennab, M., & Mcheick, H. (2024). Enhancing interpretability and accuracy of AI models in healthcare: a comprehensive review on challenges and future directions. In *Frontiers in Robotics and AI* (Vol. 11). Frontiers Media SA. <https://doi.org/10.3389/frobt.2024.1444763>
- Galarza Medina, K. X., Maldonado Coronel, K., & Herrera Guanopatin, M. S. (2024). Beneficios y Riesgos de la Implementación de Inteligencia Artificial en los Procesos de Diagnóstico Médico en el Ecuador. *Ciencia Latina Revista Científica Multidisciplinar*, 7(6), 7276–7299. [https://doi.org/10.37811/cl\\_rcm.v7i6.9274](https://doi.org/10.37811/cl_rcm.v7i6.9274)
- Geis, J. R., Brady, A., Wu, C. C., Spencer, J., Ranschaert, E., Jaremko, J. L., Langer, S. G., Kitts, A. B., Birch, J., Shields, W. F., van den Hoven van Genderen, R., Kotter, E., Gichoya, J. W., Cook, T. S., Morgan, M. B., Tang, A., Safdar, N. M., & Kohli, M. (2019). Ethics of artificial intelligence in radiology: summary of the joint European and North American multisociety statement. *Insights into Imaging*, 10(1). <https://doi.org/10.1186/s13244-019-0785-8>
- Gómez Rodríguez, S., Araya Umaña, L., Madriz Obando, E., Montenegro Cerdas, D., & Sánchez Sala, V. (n.d.). *El futuro de la radiología Digital: transformación en la imagenología y mejora de la precisión diagnóstica*. Retrieved <https://www.revista-portalesmedicos.com/revista-medica/el-futuro-de-la-radiologia-digital-transformacion-en-la-imagenologia-y-mejora-de-la-prec>

Gonçalves, F. L., Souza, H. V. da P., Almeida, F. M. de, & Pinto, M. de S. (2024). Utilização de ferramentas de Inteligência Artificial (IA) no diagnóstico de imagem. *Research, Society and Development*, 13(11), e64131147312. <https://doi.org/10.33448/rsd-v13i11.47312>

Han, R., Acosta, J. N., Shakeri, Z., Ioannidis, J. P. A., Topol, E. J., & Rajpurkar, P. (2024). Randomised controlled trials evaluating artificial intelligence in clinical practice: a scoping review. In *The Lancet Digital Health* (Vol. 6, Number 5, pp. e367–e373). Elsevier Ltd. [https://doi.org/10.1016/S2589-7500\(24\)00047-5](https://doi.org/10.1016/S2589-7500(24)00047-5)

Herington, J., McCradden, M. D., Creel, K., Boellaard, R., Jones, E. C., Jha, A. K., Rahmim, A., Scott, P. J. H., Sunderland, J. J., Wahl, R. L., Zuehlsdorff, S., & Saboury, B. (2023). Ethical considerations for artificial intelligence in medical imaging: Data collection, development, and evaluation. *Journal of Nuclear Medicine*, 64(12), 1848–1854. <https://doi.org/10.2967/jnumed.123.266080>

Iglesias López, D. (n.d.-a). *Revista Cubana de Informática Médica* 2023;15(1):e624  
*Este documento está bajo Licencia de Creative Commons Reconocimiento-NoComercial 4.0 Internacional Artículo de revisión Impacto de la Inteligencia Artificial en la Radiología Impact of Artificial Intelligence in Radiology.*

Iglesias López, D. (n.d.-b). *Revista Cubana de Informática Médica* 2023;15(1):e624  
*Este documento está bajo Licencia de Creative Commons Reconocimiento-NoComercial 4.0 Internacional Artículo de revisión Impacto de la Inteligencia Artificial en la Radiología Impact of Artificial Intelligence in Radiology.*

*INTELIGÊNCIA ARTIFICIAL EM IMAGENS MÉDICAS: IMPACTOS E DESAFIOS*  
*Artificial Intelligence in Medical Imaging: Impacts and Challenges.* (n.d.).

*INTELIGÊNCIA ARTIFICIAL NA INTERPRETAÇÃO DE EXAMES*  
*RADIOLÓGICOS – ISSN 1678-0817 Qualis B2.* (n.d.).

- Kelly, B. S., Judge, C., Bollard, S. M., Clifford, S. M., Healy, G. M., Aziz, A., Mathur, P., Islam, S., Yeom, K. W., Lawlor, A., & Killeen, R. P. (2022). Radiology artificial intelligence: a systematic review and evaluation of methods (RAISE). In *European Radiology* (Vol. 32, Number 11, pp. 7998–8007). Springer Science and Business Media Deutschland GmbH. <https://doi.org/10.1007/s00330-022-08784-6>
- Kocak, B., Ponsiglione, A., Romeo, V., Ugga, L., Huisman, M., & Cuocolo, R. (2025). Radiology AI and sustainability paradox: environmental, economic, and social dimensions. In *Insights into Imaging* (Vol. 16, Number 1). Springer Science and Business Media Deutschland GmbH. <https://doi.org/10.1186/s13244-025-01962-2>
- Koçak, B., Ponsiglione, A., Stanzione, A., Bluethgen, C., Santinha, J., Ugga, L., Huisman, M., Klontzas, M. E., Cannella, R., & Cuocolo, R. (2025). Bias in artificial intelligence for medical imaging: fundamentals, detection, avoidance, mitigation, challenges, ethics, and prospects. In *Diagnostic and Interventional Radiology* (Vol. 31, Number 2, pp. 75–88). Galenos Publishing House. <https://doi.org/10.4274/dir.2024.242854>
- Kohli, M., Prevedello, L. M., Filice, R. W., & Geis, J. R. (2017). Implementing machine learning in radiology practice and research. In *American Journal of Roentgenology* (Vol. 208, Number 4, pp. 754–760). American Roentgen Ray Society. <https://doi.org/10.2214/AJR.16.17224>
- Kotter, E., D'Antonoli, T. A., Cuocolo, R., Hierath, M., Huisman, M., Klontzas, M. E., Martí-Bonmatí, L., May, M. S., Neri, E., Nikolaou, K., Pinto dos Santos, D., Radzina, M., Shelmerdine, S. C., & Bellemo, A. (2025). Guiding AI in radiology: ESR's recommendations for effective implementation of the European AI Act. *Insights into Imaging*, 16(1), 33. <https://doi.org/10.1186/s13244-025-01905-x>

- Krishna NK, R., R.S., A., & K, S. (2025). Artificial Intelligence in Radiology: Augmentation, Not Replacement. *Cureus*.  
<https://doi.org/10.7759/cureus.86247>
- Lång, K., Josefsson, V., Larsson, A. M., Larsson, S., Högberg, C., Sartor, H., Hofvind, S., Andersson, I., & Rosso, A. (2023). Artificial intelligence-supported screen reading versus standard double reading in the Mammography Screening with Artificial Intelligence trial (MASAI): a clinical safety analysis of a randomised, controlled, non-inferiority, single-blinded, screening accuracy study. *The Lancet Oncology*, 24(8), 936–944.  
[https://doi.org/10.1016/S1470-2045\(23\)00298-X](https://doi.org/10.1016/S1470-2045(23)00298-X)
- Lanzagorta-Ortega, D., Carrillo-Pérez, D. L., & Carrillo-Esper, R. (2022). Artificial intelligence in medicine: present and future. *Gaceta Medica de Mexico*, 158, 55–59. <https://doi.org/10.24875/GMM.M22000688>
- Lawrence, R., Dodsworth, E., Massou, E., Sherlaw-Johnson, C., Ramsay, A. I. G., Walton, H., O'Regan, T., Gleeson, F., Crellin, N., Herbert, K., Ng, P. L., Elphinstone, H., Mehta, R., Lloyd, J., Halliday, A., Morris, S., & Fulop, N. J. (2025). Artificial intelligence for diagnostics in radiology practice: a rapid systematic scoping review. *EClinicalMedicine*, 83.  
<https://doi.org/10.1016/j.eclinm.2025.103228>
- Liu, H., Ding, N., Li, X., Chen, Y., Sun, H., Huang, Y., Liu, C., Ye, P., Jin, Z., Bao, H., & Xue, H. (2024). Artificial Intelligence and Radiologist Burnout. *JAMA Network Open*, 7(11). <https://doi.org/10.1001/jamanetworkopen.2024.48714>
- Moraes, J. J. de, Vieira, P. H. C., Barbosa, M. C. M. de A., Costa, A. C. M. de S. F. da, Romeiro, E. T., Terebinto, D. V., Vale, M. de C. do, Almeida, M. O. de, Pinto, S. P. T., & Zbierski, M. de L. (2023). IMPACTO DA TECNOLOGIA DE INTELIGÊNCIA ARTIFICIAL NA MEDICINA DIAGNÓSTICA. *Revista Iberoamericana de Humanidades, Ciências e Educação*, 9(7), 1303–1214.  
<https://doi.org/10.51891/rease.v9i7.10699>

- Muhammad, D., & Bendeche, M. (2024a). Unveiling the black box: A systematic review of Explainable Artificial Intelligence in medical image analysis. In *Computational and Structural Biotechnology Journal* (Vol. 24, pp. 542–560). Elsevier B.V. <https://doi.org/10.1016/j.csbj.2024.08.005>
- Muhammad, D., & Bendeche, M. (2024b). Unveiling the black box: A systematic review of Explainable Artificial Intelligence in medical image analysis. In *Computational and Structural Biotechnology Journal* (Vol. 24, pp. 542–560). Elsevier B.V. <https://doi.org/10.1016/j.csbj.2024.08.005>
- Nagendran, M., Chen, Y., Lovejoy, C. A., Gordon, A. C., Komorowski, M., Harvey, H., Topol, E. J., Ioannidis, J. P. A., Collins, G. S., & Maruthappu, M. (2020). Artificial intelligence versus clinicians: Systematic review of design, reporting standards, and claims of deep learning studies in medical imaging. *The BMJ*, 368. <https://doi.org/10.1136/bmj.m689>
- Najjar, R. (2023). Redefining Radiology: A Review of Artificial Intelligence Integration in Medical Imaging. In *Diagnostics* (Vol. 13, Number 17). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/diagnostics13172760>
- Neri, E., de Souza, N., Brady, A., Bayarri, A. A., Becker, C. D., Coppola, F., & Visser, J. (2019). What the radiologist should know about artificial intelligence – an ESR white paper. *Insights into Imaging*, 10(1). <https://doi.org/10.1186/s13244-019-0738-2>
- Obuchowicz, R., Lasek, J., Wodziński, M., Piórkowski, A., Strzelecki, M., & Nurzynska, K. (2025). Artificial Intelligence-Empowered Radiology—Current Status and Critical Review. In *Diagnostics* (Vol. 15, Number 3). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/diagnostics15030282>

- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ... Moher, D. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. In *BMJ* (Vol. 372). BMJ Publishing Group. <https://doi.org/10.1136/bmj.n71>
- Pinto-Coelho, L. (2023). How Artificial Intelligence Is Shaping Medical Imaging Technology: A Survey of Innovations and Applications. In *Bioengineering* (Vol. 10, Number 12). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/bioengineering10121435>
- Puentes, G., Salinas Miranda, E., & Triana, G. A. (n.d.). *Artículo de Revisión*.
- Rojas, R. (2020). Artificial intelligence vs human intelligence: will radiologists be needed in the future? *Radiología (English Edition)*, 62(1), 1–2. <https://doi.org/10.1016/j.rxeng.2019.12.003>
- Seyyed-Kalantari, L., Zhang, H., McDermott, M. B. A., Chen, I. Y., & Ghassemi, M. (2021). Underdiagnosis bias of artificial intelligence algorithms applied to chest radiographs in under-served patient populations. *Nature Medicine*, 27(12), 2176–2182. <https://doi.org/10.1038/s41591-021-01595-0>
- Shin, H. J., Han, K., Ryu, L., & Kim, E. K. (2023). The impact of artificial intelligence on the reading times of radiologists for chest radiographs. *Npj Digital Medicine*, 6(1). <https://doi.org/10.1038/s41746-023-00829-4>
- Stogiannos, N., Cuocolo, R., Akinci D'Antonoli, T., Pinto dos Santos, D., Harvey, H., Huisman, M., Kocak, B., Kotter, E., Lekadir, K., Shelmerdine, S. C., van Leeuwen, K. G., van Ooijen, P., Klontzas, M. E., & Malamateniou, C. (2025). Recognising errors in AI implementation in radiology: A narrative review. In *European Journal of Radiology* (Vol. 191). Elsevier Ireland Ltd. <https://doi.org/10.1016/j.ejrad.2025.112311>

TEmA, Revi. DE, Aguirre, F., Carballo, L., González, X., & Gigirey, V. (n.d.). *INTELIGENCIA ARTIFICIAL APLICADA A LA ImAGEN mÉDICA*.

Velamala, B. S., Gautam, S., & Lohani, S. (2025). Role of Artificial Intelligence in Reducing Error Rates in Radiology: A Scoping Review. *Cureus*. <https://doi.org/10.7759/cureus.91957>

Waller, J., O'connor, A., Rafaat, E., Amireh, A., Dempsey, J., Martin, C., & Umair, M. (2022). Applications and challenges of artificial intelligence in diagnostic and interventional radiology. In *Polish Journal of Radiology* (Vol. 87, Number 1, pp. e113–e117). Termedia Publishing House Ltd. <https://doi.org/10.5114/pjr.2022.113531>

Wenderott, K., Krups, J., Zaruchas, F., & Weigl, M. (2024). Effects of artificial intelligence implementation on efficiency in medical imaging—a systematic literature review and meta-analysis. In *npj Digital Medicine* (Vol. 7, Number 1). Nature Research. <https://doi.org/10.1038/s41746-024-01248-9>

World Health Organization (WHO). (2024). *Ethics and Governance of Artificial Intelligence for Health*. World Health Organization.

Yaynishet, Y. A., Nasir, F. M., Hailu, S. S., Solomon, D. Z., Gidena, E. K., & Bedewi, A. M. (2024). *Medical Students' Attitude towards Artificial Intelligence in Medicine: A National Multicenter Survey*. <https://doi.org/10.21203/rs.3.rs-3655543/v1>

Yoo, H., Lee, S. H., Arru, C., Khera, R. D., Singh, R., Siebert, S., Kim, D., Lee, Y., Park, J. H., Eom, H., Digumarthy, S., & Kalra, M. (2021). AI-based improvement in lung cancer detection on chest radiographs: results of a multi-reader study in NLST dataset. *European Radiology*, 31, 9664–9674. <https://doi.org/10.1007/s00330-021-08074-7>

Zanardo, M., Visser, J. J., Colarieti, A., Cuocolo, R., Klontzas, M. E., Pinto dos Santos, D., & Sardanelli, F. (2024). Impact of AI on radiology: a EuroAIM/EuSoMII 2024 survey among members of the European Society of Radiology. *Insights into Imaging*, 15(1). <https://doi.org/10.1186/s13244-024-01801-w>