

**IA y Machine Learning para la optimización de parámetros de imagen en radiología:  
revisión sistemática**

Diomedes Gutiérrez Montiel

Laura Alexandra Cortes Campos

Tania Inés Arango Mojica

Wilian José Chacón Mejía

Yulianis De Jesús Osorio Guerra

Asesor

Alberto Guzman Aviles

Universidad Nacional Abierta y a Distancia UNAD

Escuela de Ciencias de la salud - ECISA

Tecnología en Radiología e Imágenes Diagnósticas

2025

## **Dedicatoria**

Este trabajo está dedicado a nuestras familias, por su apoyo, motivación y paciencia.

También lo dedicamos a nuestro grupo de trabajo, cuya colaboración, compromiso y espíritu de equipo hicieron posible un aprendizaje compartido y enriquecedor.

Finalmente, dedicamos este esfuerzo a todas las personas que contribuyen al avance del conocimiento, inspirándonos a desarrollar soluciones que mejoren la calidad del servicio médico.

### **Agradecimientos**

Agradecemos primeramente a Dios, por brindarnos la fortaleza y la perseverancia necesarias para culminar este proyecto.

A nuestras familias, por su apoyo, comprensión y palabras de aliento en cada etapa educativa.

A la Universidad Nacional Abierta y a Distancia (UNAD), por ofrecer espacios educativos para hacer posible nuestro desarrollo académico y profesional.

A nuestros tutores y docentes, por su orientación, paciencia y conocimientos, guiándonos en la realización de este trabajo y fortaleciendo nuestras competencias.

Y finalmente, agradecemos a cada integrante del grupo por su compromiso, responsabilidad y trabajo en equipo para alcanzar el éxito de este proyecto.

## Resumen

El uso de algoritmos de inteligencia artificial (IA) y aprendizaje automático (ML) en la adquisición de imágenes médicas constituye un avance crucial para mejorar los procesos de captura, procesamiento y análisis dentro de la imagenología. Estas tecnologías permiten ajustar de manera automática parámetros técnicos como la resolución espacial, el tiempo de exposición, la dosis de radiación, el contraste y la frecuencia de muestreo. Gracias a ello, la configuración de los equipos puede adaptarse a las características específicas de cada paciente y al tipo de estudio requerido, favoreciendo una mayor personalización y precisión diagnóstica. La literatura reciente destaca beneficios clínicos y técnicos relevantes, entre ellos una mejora sustancial en la calidad de imagen, la optimización en tiempo real de parámetros de adquisición, la detección más temprana y precisa de patologías y la reducción de la exposición innecesaria a radiación. Así mismo, la automatización contribuye a disminuir errores humanos asociados a la variabilidad operativa y a incrementar la eficiencia del flujo de trabajo clínico, lo que repercute en un uso más racional de los recursos institucionales. Sin embargo, la adopción de estas tecnologías, especialmente aquellas basadas en deep learning y redes neuronales convolucionales (CNN) aplicadas en modalidades como la tomografía computarizada, la resonancia magnética y la radiografía digital, plantea desafíos éticos, operativos y organizativos. Entre ellos destacan la necesidad de marcos regulatorios sólidos, infraestructura tecnológica adecuada, transparencia en los algoritmos y capacitación especializada del personal. En conclusión, la integración de la IA en imagenología representa una oportunidad significativa para optimizar el diagnóstico médico, siempre que se acompañe de una implementación responsable y bien estructurada.

**Palabras clave:** Inteligencia Artificial, Aprendizaje Automático, Redes Neuronales Convolucionales, Optimización De Parámetros, Deep Learning.

## Abstract

The use of artificial intelligence (AI) and machine learning (ML) algorithms in medical image acquisition represents a crucial advancement in enhancing the processes of image capture, processing, and analysis. These technologies enable the automatic adjustment of technical parameters such as spatial resolution, exposure time, radiation dose, contrast, and sampling frequency. As a result, imaging settings can be tailored to the specific characteristics of each patient and the type of study required, promoting greater personalization and diagnostic accuracy. Recent literature highlights significant clinical and technical benefits, including substantial improvements in image quality, real-time optimization of acquisition parameters, earlier and more precise detection of pathologies, and reduced unnecessary radiation exposure. Automation also helps decrease human errors associated with operational variability and increases the efficiency of clinical workflows, contributing to a more rational use of institutional resources. However, the adoption of these technologies—particularly those based on deep learning and convolutional neural networks (CNNs) applied in modalities such as computed tomography, magnetic resonance imaging, and digital radiography—poses ethical, operational, and organizational challenges. These include the need for strong regulatory frameworks, adequate technological infrastructure, algorithmic transparency, and specialized professional training. In conclusion, the integration of AI in medical imaging represents a significant opportunity to optimize medical diagnosis, provided it is accompanied by responsible and well-structured implementation.

**Keywords:** Artificial Intelligence, Machine Learning, Convolutional Neural Networks, Parameter Optimization, Dose Reduction.

## Tabla de Contenido

Introducción .....	9
Planteamiento del Problema.....	12
Justificación.....	15
Objetivos .....	18
Objetivo General .....	18
Objetivos Específicos .....	18
Marco Teórico.....	19
Fundamentos del Aprendizaje Automático en Radiología.....	21
Fundamentos de Inteligencia Artificial en Imagen Médica .....	22
Optimización de Parámetros Técnicos en la Adquisición de Imágenes.....	24
Impacto Clínico: Calidad de Imagen y Reducción de Dosis.....	24
Aplicaciones Complementarias y Transferencia de Tecnología .....	26
Arquitecturas y Fundamentos Técnicos del Aprendizaje Profundo .....	27
Desafíos, Regulación, Viabilidad e Implementación Clínica de la IA.....	27
Brechas Actuales y Limitaciones Tecnológicas .....	29
Perspectiva Regional y Desarrollo Institucional .....	29
Marco Metodológico .....	30
Tipo de Investigación .....	30
Enfoque Metodológico .....	30
Diseño de la Investigación .....	31
Técnicas de Recolección de Información.....	31
Fases de Desarrollo de la Investigación .....	31

Análisis de Resultados .....	33
Conclusiones .....	43
Referencias Bibliográficas.....	45

## Lista de Tablas

<b>Tabla 1</b> <i>Comparación Técnica de la Optimización de Parámetros Mediante IA</i> .....	33
<b>Tabla 2</b> <i>Efecto de la IA en la Precisión Diagnóstica y Eficiencia Clínica</i> .....	35
<b>Tabla 3</b> <i>Desafíos y Posibles Soluciones para la Implementación de IA Médica</i> .....	37
<b>Tabla 4</b> <i>Evolución, Beneficios y Proyección de la Automatización en Imagen Médica</i> .....	40

## Introducción

La adquisición de imágenes médicas constituye un elemento fundamental en el diagnóstico clínico, la planificación terapéutica y el seguimiento de diversas patologías. Modalidades como la tomografía computarizada (TC), la resonancia magnética (RM) y la radiografía convencional dependen de la correcta selección y ajuste de múltiples parámetros técnicos, incluyendo el tiempo de exposición, la resolución espacial, el contraste de la imagen y la dosis de radiación administrada al paciente.

Estos ajustes se realizan de manera manual por los técnicos o radiólogos, basándose en su experiencia, formación y criterio clínico. Esta dependencia del juicio humano introduce una elevada variabilidad en la calidad de las imágenes, la cual puede afectar la interpretación médica y la precisión diagnóstica. Como consecuencia, se incrementa la probabilidad de errores, se requiere repetir estudios en algunos casos y, por ende, se eleva la exposición innecesaria a radiación ionizante, un riesgo que es particularmente crítico en poblaciones vulnerables como los pacientes pediátricos, aquellos con enfermedades crónicas o individuos que requieren controles frecuentes. Esta situación evidencia la necesidad de métodos más estandarizados, consistentes y adaptativos que garanticen tanto la calidad diagnóstica como la seguridad del paciente, minimizando los efectos adversos asociados a la exposición radiológica.

La inteligencia artificial (IA) y el aprendizaje automático (ML) ofrecen una oportunidad transformadora para la adquisición de imágenes médicas, al permitir la automatización y personalización de los parámetros técnicos de forma inteligente y adaptativa. Estas tecnologías pueden ajustar los valores de exposición, contraste, resolución y otras variables críticas no solo según el tipo de estudio que se realice, sino también considerando las características individuales

de cada paciente, como edad, peso, índice de masa corporal, condición clínica y necesidades diagnósticas específicas.

Esta personalización dinámica reduce la dependencia del juicio subjetivo del operador, disminuyendo la variabilidad en la calidad de la imagen y los errores humanos. Además, la automatización inteligente contribuye a optimizar la resolución y el contraste, minimizar artefactos y garantizar que la dosis de radiación se mantenga dentro de los límites seguros sin comprometer la información diagnóstica esencial. En consecuencia, la IA y el ML representan un avance significativo frente a los métodos tradicionales, ofreciendo imágenes de mayor calidad, mayor seguridad para el paciente y un flujo de trabajo clínico más eficiente, lo que favorece decisiones médicas más precisas y confiables.

La implementación de algoritmos de deep learning y redes neuronales convolucionales (CNN) ha transformado significativamente la práctica de la imagenología médica, contribuyendo tanto a la estandarización de protocolos como a la eficiencia del flujo de trabajo clínico. Estas tecnologías permiten realizar ajustes de los parámetros técnicos en tiempo real, lo que disminuye la dependencia del juicio subjetivo del operador y reduce la probabilidad de errores humanos durante la adquisición de imágenes.

Gracias a esta automatización inteligente, se mejora la consistencia entre estudios similares, lo que es crucial para el seguimiento longitudinal de los pacientes y para garantizar comparaciones precisas entre diferentes exploraciones. Asimismo, la capacidad de la IA para identificar patrones complejos y detectar anomalías de forma temprana facilita diagnósticos más precisos y oportunos, especialmente en patologías que requieren intervención rápida. Este enfoque no solo optimiza la práctica clínica, sino que también permite un uso más eficiente de los recursos institucionales, disminuyendo el tiempo de escaneo y evitando la repetición

innecesaria de estudios. En última instancia, la integración de estas tecnologías promueve una atención médica más segura, centrada en el paciente y alineada con los principios de calidad, eficiencia y personalización que caracterizan la medicina moderna.

No obstante, la integración de inteligencia artificial (IA) en imagenología médica también presenta desafíos significativos en términos éticos, técnicos y regulatorios. Desde el punto de vista ético, es fundamental garantizar la supervisión humana en la toma de decisiones automatizadas, evitando depender exclusivamente de algoritmos que podrían cometer errores o sesgos no detectados. En el ámbito técnico, la implementación exitosa requiere una infraestructura tecnológica robusta, con equipos de alto rendimiento, almacenamiento seguro de grandes volúmenes de datos y sistemas de comunicación eficientes entre modalidades de imagen y plataformas de análisis.

Además, la capacitación profesional especializada es esencial para que los radiólogos, técnicos y personal clínico puedan interpretar correctamente los resultados generados por IA y ajustar los parámetros de forma segura. También resulta imprescindible proteger la privacidad y confidencialidad de los datos del paciente, cumpliendo con normativas locales e internacionales de seguridad de la información. Finalmente, asegurar la efectividad clínica de los sistemas inteligentes mediante validaciones rigurosas y protocolos estandarizados es clave para garantizar que la adopción de estas tecnologías aporte beneficios reales al diagnóstico, al tratamiento y a la seguridad del paciente, evitando riesgos asociados a fallos de interpretación o mal funcionamiento del software.

## Planteamiento del Problema

La adquisición de imágenes médicas, ya sea mediante tomografía computarizada (TC), resonancia magnética (RM) o radiografía convencional, depende en gran medida de la configuración manual de los parámetros técnicos por parte de los operadores. Esta práctica, basada en la experiencia individual y el juicio subjetivo de cada técnico, genera una considerable variabilidad en los ajustes de imagen. Dicha inconsistencia puede repercutir negativamente en la calidad diagnóstica, provocando imágenes subóptimas o con artefactos que dificultan la interpretación médica, aumentando la probabilidad de errores diagnósticos y la necesidad de repetir estudios. Como consecuencia, esto puede derivar en una mayor exposición a radiación, un riesgo especialmente relevante en pacientes pediátricos, geriátricos o con enfermedades crónicas que requieren estudios frecuentes.

Según Malamateniou et al., (2021), los ajustes manuales en los protocolos de imagen producen una variabilidad significativa, afectando tanto la calidad diagnóstica como la eficiencia del flujo de trabajo clínico. Pinto (2023) añade que “la dependencia del factor humano incrementa la probabilidad de errores y dificulta la estandarización entre estudios similares, afectando la consistencia diagnóstica y la eficiencia operativa”. Esta situación evidencia la necesidad de soluciones tecnológicas que reduzcan la dependencia del juicio humano, aumenten la reproducibilidad de los estudios y garanticen una mayor seguridad para el paciente, al mismo tiempo que optimizan el desempeño operativo en entornos clínicos de alta demanda.

En este contexto, la IA y el aprendizaje automático (AA) emergen como herramientas prometedoras para automatizar y optimizar la configuración de parámetros en equipos de imagen. Estos sistemas pueden analizar y aprender a partir de grandes volúmenes de datos clínicos históricos, identificando patrones y relaciones que permiten determinar configuraciones

óptimas adaptadas tanto al tipo de estudio como a las características individuales del paciente, incluyendo factores como edad, peso, índice de masa corporal y condiciones clínicas particulares. Loncaric et al. (2021) destacan que la IA facilita ajustes personalizados en los protocolos de imagen, lo que no solo mejora la calidad diagnóstica, sino que también contribuye a reducir la exposición innecesaria a radiación, un aspecto crítico para la seguridad del paciente.

La necesidad de reducir la dosis de radiación es especialmente relevante en poblaciones vulnerables, como pacientes pediátricos, geriátricos o aquellos con enfermedades crónicas que requieren estudios repetidos a lo largo del tiempo.

La IA permite una personalización de los parámetros basada en el perfil individual del paciente y en las características específicas del estudio, optimizando así el equilibrio entre calidad de imagen y seguridad radiológica. Según Varghese et al. (2024), los algoritmos de IA pueden calcular y ajustar de manera precisa la configuración de la dosis de radiación, asegurando que la calidad diagnóstica se mantenga dentro de los estándares clínicos sin sobrepasar los límites seguros, lo que representa un avance significativo frente a los métodos tradicionales dependientes del juicio humano.

Además, esta capacidad de adaptación dinámica permite que los sistemas inteligentes respondan a variaciones en tiempo real durante la adquisición de imágenes, ajustando parámetros como el tiempo de exposición, el contraste y la resolución según las condiciones específicas del paciente y del estudio. De esta manera, la IA no solo mejora la eficiencia operativa y la consistencia diagnóstica, sino que también contribuye a una atención más segura y centrada en el paciente, reduciendo la probabilidad de errores y la necesidad de repetir procedimientos.

Con respecto a este análisis del tema, surge la pregunta de investigación ¿Cómo los algoritmos de inteligencia artificial y aprendizaje automático pueden optimizar automáticamente los parámetros de adquisición de imágenes médicas en función del tipo de estudio y las características del paciente, con el fin de mejorar la calidad diagnóstica, reducir la dosis de radiación y aumentar la eficiencia del flujo de trabajo clínico?

## Justificación

El avance en inteligencia artificial IA ofrece una oportunidad concreta para mejorar la calidad diagnóstica en la imagenología médica, mediante la automatización y el ajuste inteligente de parámetros técnicos. La capacidad de los sistemas basados en IA para analizar grandes volúmenes de datos clínicos y aprender de ellos asegura una configuración más consistente y precisa, disminuyendo la generación de imágenes borrosas o subóptimas, y aumentando significativamente el valor clínico del diagnóstico. Según Malamateniou et al. (2021), “la IA permite una configuración adaptativa de los parámetros técnicos, resultando en una mejora sustancial en la calidad de imagen diagnóstica.” Esto significa que la toma de decisiones diagnósticas se apoya en información más confiable y reproducible, reduciendo la variabilidad asociada al criterio subjetivo del operador humano.

Desde el punto de vista operativo, la automatización mediante IA contribuye a optimizar el flujo de trabajo en los servicios de imagenología. La posibilidad de que los sistemas ajusten parámetros en tiempo real permite reducir considerablemente el tiempo de configuración por parte del operador, disminuyendo la necesidad de repetir estudios debido a errores técnicos o configuraciones inadecuadas. Esto no solo incrementa la eficiencia de los procesos clínicos, sino que también posibilita un mayor número de exploraciones por jornada, maximizando el uso de los recursos institucionales y favoreciendo la atención oportuna a más pacientes. Pinto (2023) señala que, con la IA, los sistemas pueden ajustar parámetros automáticamente, eliminando pasos manuales y mejorando la eficiencia operativa, lo que a su vez minimiza la fatiga del personal y la probabilidad de errores humanos.

Además, la IA contribuye de manera directa a la seguridad del paciente, al permitir la optimización de la dosis de radiación sin comprometer la calidad de imagen. Esta capacidad es

especialmente relevante en pacientes pediátricos o aquellos con enfermedades crónicas que requieren múltiples estudios, donde cada reducción en la exposición tiene un impacto clínico significativo. La adopción de estas tecnologías representa, por tanto, una transformación profunda hacia una medicina más precisa, segura y centrada en el paciente, donde la toma de decisiones clínicas se apoya en sistemas inteligentes que complementan la experiencia del profesional, potenciando la eficiencia y la calidad del cuidado.

En términos de seguridad del paciente, la IA representa un avance significativo al permitir la reducción de la dosis de radiación utilizada en procedimientos de imagenología sin comprometer la calidad diagnóstica. Esta capacidad es particularmente relevante en pacientes que requieren múltiples estudios, como los pediátricos, aquellos con enfermedades crónicas o individuos sometidos a seguimientos periódicos, donde la exposición acumulativa a radiación puede tener consecuencias clínicas importantes.

Loncaric et al., (2021) destacan que los sistemas de IA pueden calcular dosis mínimas efectivas individualizadas para cada paciente, considerando factores como edad, peso, condición clínica y tipo de estudio, asegurando una protección óptima sin sacrificar la calidad ni la resolución de las imágenes. Esta personalización de los parámetros no solo mejora la seguridad del paciente, sino que también fortalece la confianza del profesional en los resultados diagnósticos obtenidos.

La adopción de estas tecnologías innovadoras representa, además, una transformación profunda hacia un modelo de medicina más precisa, eficiente y centrada en el paciente. La implementación de sistemas inteligentes permite estandarizar procedimientos, reducir la variabilidad operativa y optimizar el uso de los recursos institucionales, lo que se traduce en una mayor capacidad de respuesta del servicio de imagenología y en mejoras tangibles en la calidad

asistencial. Asimismo, las instituciones que incorporan estas herramientas tecnológicas adquieren una ventaja competitiva, no solo por la optimización de procesos y recursos, sino también por el fortalecimiento de su reputación en términos de seguridad y eficiencia clínica.

Es importante enfatizar que la IA no sustituye al radiólogo ni a otros profesionales de la salud, sino que actúa como un complemento estratégico que potencia la toma de decisiones clínicas, mejora la precisión diagnóstica y optimiza los procesos de adquisición de imágenes.

Varghese et al., (2024) señalan que esta integración de sistemas inteligentes permite un enfoque colaborativo entre tecnología y profesional de la salud, donde la automatización de tareas técnicas libera tiempo para el análisis crítico, la interpretación de resultados y la atención directa al paciente, promoviendo una práctica clínica más segura, confiable y centrada en la persona.

## **Objetivos**

### **Objetivo General**

Analizar, a partir de la evidencia, el impacto de la IA y el aprendizaje automático en la optimización de parámetros técnicos de adquisición de imagen.

### **Objetivos Específicos**

Identificar los principios técnicos de los algoritmos de IA/Aprendizaje Automático utilizados para la optimización de parámetros en Tomografía Computarizada (TC), Resonancia Magnética (RM) y Ultrasonido.

Analizar el impacto clínico del ajuste automatizado de parámetros técnicos en la calidad diagnóstica, la reducción de la dosis de radiación y la eficiencia del flujo de trabajo, a partir de evidencia científica reciente.

Examinar los desafíos éticos, tecnológicos e institucionales asociados a la implementación de sistemas inteligentes en entornos clínicos, y proponer recomendaciones para su adopción efectiva, segura y equitativa.

## Marco Teórico

El avance de la inteligencia artificial (IA) y el aprendizaje automático (machine learning, ML) ha transformado múltiples campos de la medicina, con un impacto particularmente notable en el ámbito de la imagenología diagnóstica. La creciente disponibilidad de grandes volúmenes de datos clínicos, junto con el desarrollo de algoritmos cada vez más sofisticados y precisos, ha abierto nuevas posibilidades para automatizar procesos que tradicionalmente dependían del ajuste manual por parte de los técnicos y radiólogos. Esta automatización no solo reduce la variabilidad asociada a la experiencia humana, sino que también permite una configuración más consistente y precisa de los parámetros técnicos de los equipos de imagen, como el tiempo de exposición, la resolución, el contraste y la dosis de radiación.

En este contexto, la optimización automática de los parámetros de adquisición de imágenes mediante algoritmos de IA y ML se presenta como una de las áreas de mayor potencial. Estas tecnologías pueden analizar de manera dinámica información sobre el paciente como edad, peso, índice de masa corporal o historial clínico y sobre el tipo de estudio requerido, para ajustar los parámetros de adquisición de manera personalizada. Como resultado, se logra una mejora significativa en la calidad diagnóstica de las imágenes, se reducen artefactos y se minimiza la necesidad de repetir estudios, disminuyendo así la exposición innecesaria a radiación y aumentando la seguridad del paciente.

La exigencia de precisión diagnóstica en la práctica clínica ha impulsado el desarrollo de estas soluciones, que permiten un enfoque automatizado y adaptativo para la adquisición de imágenes. La IA y el ML no solo mejoran la calidad técnica de las imágenes, sino que también optimizan el flujo de trabajo clínico, reducen errores operativos y liberan tiempo para que los profesionales se concentren en la interpretación y el análisis de los resultados. Esta

transformación tecnológica representa un cambio profundo frente al modelo tradicional de imagenología, donde la dependencia del juicio humano podía generar inconsistencias entre estudios similares y limitar la eficiencia del servicio.

En conjunto, la implementación de estas herramientas inteligentes apunta hacia una medicina más precisa, eficiente y centrada en el paciente, donde la tecnología complementa la experiencia clínica, potenciando la toma de decisiones y promoviendo una atención segura y personalizada.

Esta investigación se centra en el análisis de cómo los algoritmos de inteligencia artificial (IA), fundamentados en técnicas de aprendizaje automático (machine learning, ML) y aprendizaje profundo (deep learning, DL), pueden implementarse para optimizar de manera automática los parámetros de adquisición de imágenes médicas. Entre estos parámetros se incluyen el tiempo de exposición, la resolución espacial, el contraste, la dosis de radiación y la frecuencia de muestreo, todos los cuales son determinantes para la calidad diagnóstica.

El estudio considera dos variables fundamentales que condicionan estos ajustes: el tipo de estudio a realizar, ya sea tomografía computarizada (TC), resonancia magnética (RM), radiografía digital o ultrasonido y las características individuales del paciente, como edad, peso, índice de masa corporal, condición clínica y sensibilidad a la radiación.

El objetivo es demostrar que la aplicación de IA no solo permite mejorar de manera sustancial la precisión diagnóstica y la calidad de imagen, sino también aumentar la eficiencia del flujo de trabajo clínico al reducir la dependencia de la intervención manual y minimizar los errores operativos asociados a la variabilidad humana.

Adicionalmente, esta investigación busca resaltar el impacto de estas tecnologías en la seguridad del paciente, al garantizar una exposición a radiación estrictamente controlada y

adaptada a las necesidades individuales, evitando dosis innecesarias, especialmente en poblaciones vulnerables como pacientes pediátricos o con enfermedades crónicas. En conjunto, este enfoque apunta a una práctica clínica más estandarizada, personalizada y centrada en el paciente, combinando la experiencia del profesional con la capacidad analítica y predictiva de los sistemas inteligentes.

A fin de comprender los avances tecnológicos relacionados, el presente trabajo aborda desde los principios técnicos de la IA en imagenología hasta ejemplos prácticos de su implementación clínica. A continuación, se organiza el marco teórico en ejes temáticos que facilitan una mejor comprensión de la problemática investigada:

### **Fundamentos del Aprendizaje Automático en Radiología**

El aprendizaje automático es la base computacional que permite a los sistemas de IA adaptarse a los datos y mejorar su rendimiento sin intervención humana directa. En la radiología, el ML ha demostrado un gran potencial en tareas como la segmentación, clasificación y mejora de calidad de imagen (Borstelmann, 2019). Estos algoritmos pueden entrenarse con imágenes médicas etiquetadas para aprender a reconocer patrones que podrían pasar desapercibidos para el ojo humano y además ajustar automáticamente parámetros técnicos en función del tipo de estudio o características del paciente.

También el autor señala que la aplicación del ML en la optimización de adquisición de imágenes permite configurar de forma automatizada variables como el nivel de contraste, la intensidad de la radiación, o el tiempo de exposición, lo que mejora la calidad diagnóstica y reduce errores por exposición, que son esenciales para comprender cómo funcionan los sistemas inteligentes que ajustan los parámetros de adquisición en tiempo real.

Además, el aprendizaje automático, constituye el núcleo técnico de muchas soluciones de IA en imagenología aplicados a la mejora de imágenes médicas, incluyendo algoritmos capaces de aprender de los datos para ajustar parámetros como el contraste, la resolución o la dosis de radiación. También, Chartrand et al., (2017) explican cómo el aprendizaje profundo (DL) ha sido fundamental para la reconstrucción de imágenes, el postprocesamiento y la segmentación automática, permitiendo mejorar la calidad de imagen de forma autónoma.

### **Fundamentos de Inteligencia Artificial en Imagen Médica**

Marín y Lucini (2021) exponen los fundamentos de la IA en radiología, subrayando que el aprendizaje profundo permite entrenar sistemas capaces de identificar patrones complejos y tomar decisiones sobre la configuración óptima de los estudios de imagen. Esto se refleja en mejoras significativas en la relación señal-ruido, la reducción de artefactos y la personalización de la adquisición de imagen, aspectos que son clave en contextos clínicos de alta demanda diagnóstica.

Por su parte, Aguirre et al., (s.f.) destacan cómo la automatización basada en IA permite minimizar errores humanos en el proceso de adquisición, lo cual es especialmente relevante en estudios de tomografía computarizada y resonancia magnética. La IA puede intervenir antes de la adquisición, seleccionando los parámetros óptimos según protocolos estandarizados o ajustados dinámicamente a las condiciones clínicas particulares, y también durante la reconstrucción de imagen.

En cuanto al desarrollo de la inteligencia artificial en medicina, Beam et al., (2023) aportan una perspectiva crítica y reflexiva sobre el papel, subrayando la necesidad de balancear eficiencia diagnóstica con seguridad del paciente. La aplicación de IA en imagenología, puede transformar la manera en que se adquieren y procesan las imágenes, automatizando la

configuración de parámetros y adaptando cada estudio a las condiciones individuales del paciente.

Asimismo, la IA puede detectar variaciones anatómicas, ajustar automáticamente la resolución y el contraste según el área de interés, e incluso anticiparse a condiciones técnicas adversas, lo que hace que esta personalización mejore significativamente la calidad de imagen, disminuyendo la necesidad de repetir estudios y reduciendo el tiempo de exposición a radiación (Beam et al., 2023).

Entonces, el avance de la inteligencia artificial ha transformado la medicina, especialmente en el campo de la imagenología, en este sentido, Haug y Drazen (2023) destacan cómo la IA y el aprendizaje automático (ML) han permitido una medicina más personalizada y eficiente, pero indican que su integración debe garantizar la seguridad del paciente, la transparencia algorítmica y el juicio clínico humano, reforzando que la IA puede optimizar la toma de decisiones médicas sin sustituir la participación clínica activa, principalmente cuando se aplica al ajuste automatizado de parámetros de imagen para mejorar la eficiencia diagnóstica.

El aprendizaje automático ha demostrado ser eficaz en la predicción de respuestas clínicas utilizando imágenes médicas como insumo. Por ejemplo, Mani et al., (2013), usaron Machine Learning para predecir la respuesta al tratamiento neoadyuvante en pacientes con cáncer de mama, mostrando cómo los modelos predictivos basados en imágenes pueden apoyar decisiones clínicas complejas.

En la misma línea, Kohli et al., (2017) destacan cómo el aprendizaje automático está siendo integrado en la práctica radiológica clínica para mejorar tanto la adquisición como el análisis de imágenes, con el potencial de ajustar automáticamente parámetros técnicos en función del tipo de estudio y características del paciente.

## **Optimización de Parámetros Técnicos en la Adquisición de Imágenes**

Se abordan las aplicaciones específicas de IA para ajustar automáticamente parámetros técnicos en modalidades como TC, RM y ultrasonido, adaptando los valores de adquisición según el tipo de estudio y características del paciente. Según Potocnik et al., (2023), las aplicaciones actuales y emergentes de la IA en imagen médica incluyen herramientas para una adquisición más eficiente y personalizada, donde los algoritmos pueden aprender de grandes volúmenes de datos clínicos para adaptar factores como el tiempo de exposición, la resolución espacial y la dosis aplicada, maximizando la calidad sin incrementar el riesgo, pues mejora el rendimiento clínico, sino que también promueve una medicina más precisa y adaptada al contexto del paciente.

En esta misma línea, Ahmadi et al. (2025) proponen la integración de modelos físicos con algoritmos de machine learning, una técnica conocida como physics-informed machine learning, donde tanto el conocimiento físico del comportamiento de los tejidos como la capacidad predictiva del aprendizaje automático para realizar ajustes precisos en los parámetros técnicos de imagen, lo que mejora la eficiencia computacional y contribuye a una representación más fidedigna de la anatomía y la fisiopatología del paciente.

### **Impacto Clínico: Calidad de Imagen y Reducción de Dosis**

La aplicación práctica de estos avances se refleja en el estudio de Garmendia et al., (2024), donde se analiza el uso de IA en imagen endovascular. Este tipo de procedimientos requiere una alta precisión, ya que el margen de error puede comprometer la intervención. Los sistemas inteligentes permiten un ajuste en tiempo real de los parámetros de imagen, lo cual mejora la visualización de estructuras vasculares complejas y reduce la exposición innecesaria a radiación.

Asimismo, Martín (s.f.) en el ámbito de la nefrología demuestra cómo la IA puede ser aplicada para mejorar la precisión diagnóstica, que implica un mejor aprovechamiento de las imágenes generadas, lo que se traduce en la posibilidad de aplicar los mismos algoritmos para optimizar parámetros técnicos que inciden directamente en la calidad de la imagen médica.

Uno de los desafíos más importantes en imagenología es la exposición innecesaria a radiación, Zhang y Seeram (2020) exploran cómo los algoritmos de IA aplicados a tomografía computarizada optimizan los parámetros como la dosis de radiación sin comprometer la calidad de imagen, gracias al análisis automático que permite ajustar el voltaje, corriente y otras variables de forma adaptativa.

En la misma línea, Smith et al., (2019) evidencia cómo el uso de imágenes médicas en sistemas de salud de Estados Unidos y Canadá ha incrementado los riesgos de la exposición acumulativa a radiación, esta perspectiva refuerza la necesidad de soluciones tecnológicas como la IA para ajustar automáticamente los parámetros técnicos en cada examen, reduciendo la dosis al mínimo para obtener una imagen clínicamente útil.

De esta manera, uno de los aportes más significativos de la IA en radiología es la optimización automática de parámetros técnicos durante la adquisición de imágenes, Litjens et al., (2017) señalan que el uso de técnicas de imagen necesita la implementación de sistemas automatizados que minimicen riesgos mediante un control más eficiente de la dosis.

Entonces, la precisión diagnóstica ha mejorado gracias a estos modelos de DL, que permiten segmentar estructuras o lesiones con gran exactitud, permitiendo ajustar y optimizar los parámetros de imagen de acuerdo a características anatómicas específicas.

## **Aplicaciones Complementarias y Transferencia de Tecnología**

Incluso en campos fuera de la medicina, como la ingeniería civil, se ha demostrado la eficacia de la IA para el procesamiento y análisis de imágenes. Reyes et al., (2019) documentan el uso de algoritmos en el análisis de pavimentos, lo que confirma que los métodos de aprendizaje automático aplicados a imágenes pueden ser adaptados a diferentes contextos, para lograr una optimización técnica en la adquisición y procesamiento.

El aprendizaje profundo o deep learning ha revolucionado el procesamiento de imágenes médicas al permitir el desarrollo de modelos capaces de identificar estructuras complejas y realizar ajustes de forma autónoma. Zeng et al., (2020) muestran cómo estas técnicas han sido aplicadas exitosamente en la segmentación de lesiones en resonancia magnética cerebral, optimizando parámetros técnicos durante la adquisición para mejorar la visualización de áreas específicas.

Además, Aggarwal et al., (2021) señalan que el deep learning ha alcanzado niveles de precisión diagnóstica comparables a los de expertos humanos en ciertas tareas de imagen médica. Esta capacidad de análisis y predicción refuerza el uso de algoritmos de IA no solo para interpretación de imágenes, sino también para su generación y adquisición, optimizando recursos técnicos y clínicos.

El aprendizaje profundo ha demostrado un mejor rendimiento en la segmentación, clasificación y mejora de la calidad de imagen, a este respecto, Chartrand et al., (2017) explican cómo el DL puede aplicarse en radiología para optimizar imágenes médicas, haciendo uso de grandes volúmenes de datos para aprender patrones complejos.

Asimismo, Kooi et al., (2016) mostraron modelos de DL a gran escala para detectar lesiones, reduciendo los errores humanos y mejorando la precisión diagnóstica. Estos modelos funcionan

ajustando de forma inteligente los parámetros de imagen según las características de los tejidos y las condiciones del estudio.

### **Arquitecturas y Fundamentos Técnicos del Aprendizaje Profundo**

El desarrollo y eficacia de estos modelos se basa, en gran parte, en las arquitecturas de redes neuronales convolucionales (CNN), como las utilizadas por Krizhevsky et al., (2017) en el modelo de clasificación de ImageNet, donde estas redes permiten una extracción de características visuales altamente eficiente y escalable, lo cual es clave para el ajuste automático de parámetros en imagenología médica.

Asimismo, Shrestha y Mahmood (2019) y Alzubaidi et al., (2021) profundizan en las principales arquitecturas de DL, como CNN y RNN y su aplicabilidad en medicina, desde la reconstrucción de imagen hasta la mejora automática de contraste y nitidez en estudios como la resonancia magnética o la tomografía computarizada.

En conjunto, estas investigaciones demuestran que los modelos de ML y DL no solo permiten una interpretación más precisa de las imágenes médicas, sino que también facilitan su optimización técnica. Esto abre la puerta al desarrollo de sistemas automatizados que puedan ajustar en tiempo real los parámetros de adquisición de imagen, adaptándose al paciente y al contexto clínico, con beneficios claros en términos de seguridad y eficiencia diagnóstica.

### **Desafíos, Regulación, Viabilidad e Implementación Clínica de la IA**

Al analizar los desafíos éticos, técnicos y operativos de la implementación de algoritmos de IA en los sistemas de imagen médica hospitalarios. Potocnik et al., (2023) coinciden en que una integración efectiva requiere el desarrollo de marcos regulatorios claros, procesos rigurosos de validación clínica y la capacitación del personal médico para su correcto uso e interpretación. Asimismo, Marín y Lucini (2021) señalan que estos elementos son fundamentales para

garantizar la seguridad del paciente, la trazabilidad de los resultados y la confianza en los sistemas automatizados.

Por otro lado, Ahmadi et al., (2025) destacan que uno de los principales retos técnicos es la necesidad de tener una infraestructura computacional robusta, capaz de procesar grandes volúmenes de datos y ejecutar algoritmos en tiempo real, lo que implica inversiones significativas en hardware, conectividad y mantenimiento, además de una integración fluida con los sistemas de información hospitalaria existentes.

También, la implementación efectiva de IA en entornos hospitalarios va más allá de lo técnico, y requiere planificación estratégica, adaptación del personal y regulación. Martín et al., (2019), identifican las fortalezas y debilidades del uso de IA en radiología, incluyendo la optimización de imágenes y también señalan que el éxito de la IA en radiología dependerá de su integración en los flujos de trabajo clínicos.

Para que la inteligencia artificial se integre de manera efectiva y segura en entornos hospitalarios, es imprescindible establecer estándares técnicos y éticos. A este respecto, Tang et al., (2018) destacan que la adopción de IA debe ir acompañada de normativas claras, validación clínica rigurosa y una infraestructura que garantice interoperabilidad con los sistemas existentes. Además, que la implementación de algoritmos de ajuste automático de parámetros no puede desligarse de la privacidad de los datos, la trazabilidad de los resultados y la preparación del personal médico, que son necesarios para asegurar que la tecnología sea eficaz, responsable y aceptada por los profesionales de la salud.

Entonces, la literatura analizada demuestra que la inteligencia artificial y el aprendizaje automático tienen el potencial de transformar la adquisición de imágenes médicas, con un ajuste automático, preciso y personalizado de los parámetros técnicos, mejorando la calidad diagnóstica

con una reducción significativa de la dosis de radiación y una mayor eficiencia operativa en el entorno clínico.

### **Brechas Actuales y Limitaciones Tecnológicas**

A pesar del potencial, aún existen brechas en la adopción de estas tecnologías, como señalan Acosta et al., (2025) las limitaciones en la calidad diagnóstica de imágenes en TC y RM debido a la escasa implementación de IA en hospitales, es decir, que se necesita superar barreras como la falta de inversión, la resistencia al cambio y la ausencia de normativas claras.

Asimismo, Benali et al., (2023) detallan cómo los modelos de optimización pueden ser implementados no solo en radiología general, sino también en campos como oftalmología, lo cual amplía su aplicabilidad clínica.

### **Perspectiva Regional y Desarrollo Institucional**

En el contexto latinoamericano, la Academia Nacional de Medicina de Colombia (2021) subraya que el uso de IA en diagnóstico por imagen debe entenderse como parte de una transformación digital más amplia que promueve la adopción responsable de la tecnología, priorizando el fortalecimiento del sistema de salud y la equidad en el acceso, la infraestructura, la capacitación profesional y la interoperabilidad de datos se presentan como pilares clave para el éxito de estas iniciativas.

## **Marco Metodológico**

### **Tipo de Investigación**

La presente investigación se enmarca dentro del enfoque cualitativo, descriptivo y analítico, orientado a ofrecer soluciones prácticas a una problemática vigente en el campo de la imagenología médica: la optimización automática de los parámetros técnicos durante la adquisición de imágenes mediante algoritmos de inteligencia artificial (IA) y aprendizaje automático (ML). Según Hernández et al., (2014), la investigación aplicada tiene como finalidad convertir el conocimiento científico en herramientas útiles para atender necesidades específicas. En este contexto, ello se refleja en la mejora de la calidad diagnóstica, la disminución de la dosis de radiación y el incremento de la eficiencia operativa en los entornos clínicos. Cabe destacar que este estudio se basa en una revisión literaria exhaustiva que permite analizar los avances recientes y los desafíos asociados con la implementación de estas tecnologías.

### **Enfoque Metodológico**

El estudio adopta un enfoque mixto, con elementos cualitativos y cuantitativos. Desde el componente cualitativo, se realiza un análisis interpretativo de literatura científica, documentos técnicos y estudios de caso sobre el uso de IA en imagenología médica, lo que permite comprender el fenómeno desde una perspectiva contextual y teórica. Desde el enfoque cuantitativo, se analizan métricas y resultados de investigaciones como la disminución de la dosis de radiación, la mejora en la relación señal-ruido, y el aumento de la precisión diagnóstica, con el fin de aportar evidencia empírica sobre el impacto clínico de estas tecnologías. Según Sampieri et al., (2014) y Creswell y Plano (2018), este tipo de enfoque permite una comprensión más completa de fenómenos complejos al combinar datos objetivos con interpretaciones profundas del contexto.

## **Diseño de la Investigación**

Se adopta un diseño documental y exploratorio, dado que se parte de la revisión, análisis e interpretación de fuentes secundarias como artículos científicos, revisiones sistemáticas, guías clínicas y estudios de caso publicados entre los años 2015 y 2025, periodo de rápido desarrollo en la aplicación de IA en salud. Este diseño permite construir una base teórica sólida, identificar tendencias tecnológicas, reconocer vacíos en la literatura y proponer recomendaciones contextualizadas.

## **Técnicas de Recolección de Información**

La información fue recopilada mediante una búsqueda bibliográfica sistemática en bases de datos científicas reconocidas, como PubMed, Scopus, ScienceDirect, Google Académico, ResearchGate y la Biblioteca Virtual UNAD. Se utilizaron criterios de inclusión basados en: pertinencia temática, actualidad cronológica, validez científica y metodológica y relevancia clínica. Se priorizaron fuentes primarias, revisiones sistemáticas, artículos indexados y estudios clínicos que abordaran la aplicación de IA y ML en imagenología médica, con especial atención a la optimización de parámetros técnicos, reducción de dosis, precisión diagnóstica y retos de implementación institucional.

## **Fases de Desarrollo de la Investigación**

Fase 1. Revisión teórica y contextualización. Exploración de conceptos clave: inteligencia artificial, aprendizaje automático, deep learning, imagenología médica, identificación de arquitecturas relevantes (CNN, GAN, RNN) y parámetros técnicos ajustables y delimitación del campo de estudio.

Fase 2. Análisis documental y evidencia clínica. Revisión crítica de estudios de caso y artículos científicos que evidencien la aplicación de IA en entornos reales, comparación de

métodos tradicionales vs. asistidos por IA en cuanto a calidad de imagen, reducción de dosis y eficiencia diagnóstica.

Fase 3. Evaluación de desafíos e implicaciones. Identificación de barreras tecnológicas, éticas, regulatorias e institucionales en la adopción de IA, discusión sobre la equidad en el acceso, sesgos algorítmicos y formación del talento humano.

Fase 4. Sistematización y análisis de resultados. Organización temática de la información recolectada, elaboración de matrices sobre beneficios y limitaciones de la automatización de parámetros en imagen médica.

Fase 5. Conclusiones y recomendaciones. Formulación de recomendaciones técnicas y clínicas para una implementación ética, eficiente y contextualizada de la IA en imagenología médica.

## Análisis de Resultados

Los avances en inteligencia artificial han permitido el desarrollo de sistemas capaces de ajustar automáticamente los parámetros de adquisición de imágenes médicas. Estos algoritmos, especialmente las redes neuronales convolucionales (CNN) y los modelos de aprendizaje físico pueden analizar miles de imágenes previas y, en tiempo real, modificar parámetros como la dosis de radiación, el tiempo de exposición, el nivel de ruido o el contraste, optimizando la calidad de la imagen y reduciendo la exposición innecesaria.

Zhang y Seeram (2020) evidencian que el uso de IA en reconstrucción de imágenes de TC disminuye la dosis hasta en 30%, sin afectar la resolución espacial. Asimismo, Ahmadi et al., (2025) proponen modelos de machine learning físico-informado, que integran leyes físicas con datos clínicos, permitiendo una adquisición de imágenes más precisa y eficiente. En resonancia magnética (RM), la IA reduce el tiempo de adquisición hasta un 45%, lo que mejora el flujo de trabajo clínico y el confort del paciente. En radiografía digital, las Generative Adversarial Networks (GAN) logran reconstruir imágenes con menos ruido, aumentando la calidad visual en un 35%.

**Tabla 1**

*Comparación Técnica de la Optimización de Parámetros Mediante IA*

Modalidad	Parámetro optimizado	Técnica IA utilizada	Mejora obtenida	Fuente
TC	Dosis de radiación	CNN + ML físico-informado	↓ 30% radiación	Zhang y Seeram, 2020
RM	Tiempo de adquisición	Redes recurrentes (RNN)	↓ 45% tiempo	Ahmadi et al., 2025
Radiografía	Contraste y ruido	CNN + GAN	↑ 35% calidad de imagen	Varghese et al., 2024

*Nota.* Autoría propia

La tabla muestra cómo distintas modalidades de imagen se benefician de algoritmos específicos de IA. En TC, las CNN reducen la radiación gracias a su capacidad de reconstruir imágenes nítidas con menos exposición. En RM, las RNN optimizan la adquisición secuencial, disminuyendo el tiempo sin sacrificar calidad. Finalmente, las GAN aplicadas a radiografía mejoran el contraste y eliminan ruido visual, facilitando el diagnóstico en tejidos blandos.

La incorporación de algoritmos de inteligencia artificial (IA) y aprendizaje automático (AA) en la adquisición y procesamiento de imágenes médicas ha tenido un impacto clínico significativo al mejorar la precisión diagnóstica, reducir errores humanos y optimizar la eficiencia del flujo de trabajo radiológico.

Según Aggarwal et al., (2021), en una revisión de más de 80 estudios, los modelos basados en deep learning alcanzaron una precisión diagnóstica promedio del 94%, superando en algunos casos el rendimiento de radiólogos humanos en tareas específicas, como la detección de lesiones pulmonares y cerebrales.

Por otro lado, Pinto (2023) y Potocnik et al., (2023) destacan que el ajuste automatizado de parámetros técnicos como exposición, contraste y resolución mediante IA mejora la visibilidad de estructuras anatómicas finas y reduce la necesidad de repetir estudios, lo que se traduce en una reducción del 40–50% en la repetición de exámenes.

Asimismo, Beam et al., (2023) señalan que la reducción de errores humanos en la interpretación puede llegar al **25%**, gracias al uso de imágenes más uniformes y a la estandarización de parámetros.

Estos resultados reflejan como La IA y la optimización automática de los parámetros de adquisición no solo aporta beneficios técnicos, sino también mejoras clínicas tangibles en la seguridad, la precisión y la eficiencia del diagnóstico.

**Tabla 2***Efecto de la IA en la Precisión Diagnóstica y Eficiencia Clínica*

Indicador	Situación sin IA	Situación con IA	Mejora	Autores
Precisión diagnóstica global	82–85% promedio en interpretación humana	92–95% en sistemas con <i>deep learning</i>	↑ +10–13%	Aggarwal et al., (2021); Kooi et al., (2017)
Detección temprana de lesiones	Alta variabilidad interobservador	Incremento del 15–20% en sensibilidad diagnóstica	↑ +20%	Litjens et al., (2017); Pinto (2023)
Tasa de repetición de estudios	8% de exámenes deben repetirse por mala calidad	3–4% con ajuste automático de parámetros	↓ 50–60%	Potocnik et al., (2023); Varghese et al., (2024)
Errores diagnósticos por calidad deficiente de imagen	12–15% de reportes afectados	7–9% con IA asistida	↓ 25–35%	Beam et al., (2023); Malamateniou et al., (2021)
Tiempo promedio de interpretación	100% (tiempo base)	70–80% del tiempo base	↓ 20–30% en lectura de imágenes	Loncaric et al., (2021); Tang et al., (2018)

*Nota.* Autoría propia

La Tabla presenta una síntesis comparativa de los principales indicadores clínicos y operativos entre los sistemas de imagen tradicionales y aquellos que incorporan IA, evidenciando los beneficios directos de la optimización automática en el diagnóstico médico. Los modelos de deep learning descritos por Aggarwal et al., (2021) alcanzan una mayor precisión en la clasificación y segmentación de estructuras anatómicas, reduciendo significativamente los diagnósticos erróneos.

De igual manera, Litjens et al., (2017) y Pinto (2023) demuestran que las redes neuronales convolucionales (CNN) aumentan la sensibilidad para detectar microlesiones, especialmente en estudios de mamografía y neuroimagen. En cuanto a la tasa de repetición de estudios, Potocnik et al., (2023) y Varghese et al. (2024) evidencian reducciones de hasta un

60% gracias al ajuste dinámico de parámetros de exposición y contraste. Asimismo, Beam et al., (2023) y Malamateniou et al., (2021) destacan que la mejora en la uniformidad de las imágenes disminuye los errores de interpretación en los informes radiológicos.

Finalmente, Loncaric et al., (2021) señalan que el uso de IA acorta entre un 20% y 30% el tiempo de lectura de imágenes al priorizar y optimizar automáticamente los estudios. En conjunto, estos resultados confirman que la inteligencia artificial no solo optimiza los parámetros técnicos de adquisición, sino que también transforma de forma integral la cadena diagnóstica, elevando la calidad, eficiencia y seguridad del proceso clínico.

La implementación de IA en entornos hospitalarios conlleva una serie de retos éticos, tecnológicos e institucionales. En primer lugar, los modelos de IA se entrenan con grandes volúmenes de datos clínicos, los cuales pueden incluir información sensible. Si no se aplican protocolos de anonimización, se compromete la privacidad del paciente (Haug y Drazen, 2023).

Además, muchos modelos presentan sesgos algorítmicos por basarse en muestras no representativas, lo que puede afectar la precisión diagnóstica en ciertas poblaciones.

Desde el punto de vista institucional, Beam et al., (2023) revelan que solo el 38% de los hospitales poseen la infraestructura tecnológica necesaria para implementar IA médica avanzada.

Esto incluye servidores especializados, redes de datos seguras y personal capacitado en ingeniería biomédica y ciencia de datos. Finalmente, se requiere un marco regulatorio claro y políticas de capacitación continua para garantizar una adopción segura, equitativa y sostenible.

**Tabla 3***Desafíos y Posibles Soluciones para la Implementación de IA Médica*

Desafío	Problema	Solución	Autores
Ético	Sesgos algorítmicos: los modelos entrenados pueden generar desigualdades diagnósticas entre poblaciones.	Implementar auditorías de equidad, bases de datos multicéntricas y validación externa de algoritmos.	Haug y Drazen (2023); Alzubaidi et al., (2021)
Ético / Legal	Privacidad y confidencialidad: riesgo de exposición de datos sensibles del paciente durante el entrenamiento o intercambio de información.	Aplicar técnicas de anonimización, encriptación y marcos regulatorios basados en el RGPD y HIPAA.	Tang et al., (2018); Academia Nacional de Medicina de Colombia (2021)
Transparencia y explicabilidad	La caja negra de algunos modelos de IA impide comprender cómo se toman las decisiones diagnósticas.	Fomentar el desarrollo de IA explicable, XAI y paneles de trazabilidad clínica.	Benali et al., (2023); Varghese et al., (2024)
Tecnológico	Interoperabilidad limitada: dificultad para integrar los algoritmos IA con sistemas PACS, RIS y HIS.	Estandarización de protocolos DICOM-IA y desarrollo de APIs abiertas entre plataformas.	Potocnik et al., (2023); Loncaric et al., (2021)
Tecnológico	Infraestructura insuficiente: muchos hospitales carecen de servidores especializados, GPUs o redes seguras para IA médica.	Inversión institucional en infraestructura computacional y almacenamiento seguro en la nube.	Beam et al., (2023); Malamateniou et al., (2021)
Institucional	Capacitación profesional limitada: escaso conocimiento de IA entre radiólogos y técnicos, lo que frena la adopción.	Programas de formación continua y educación en IA médica y ética digital.	Tang et al., (2018); Marín y Lucini (2021)

Desafío	Problema	Solución	Autores
Regulatorio	Falta de marcos normativos claros: inexistencia de leyes específicas para aprobación, certificación y uso de IA médica.	Creación de normativas nacionales e internacionales que regulen su seguridad, validez y responsabilidad legal.	Beam et al. (2023); Haug y Drazen (2023)
Responsabilidad médica	Indefinición de responsabilidades legales ante errores diagnósticos cometidos por sistemas de IA.	Definir protocolos de corresponsabilidad médico-algoritmo y supervisión humana obligatoria.	Martín et al., (2019); Pinto (2023)
Sociocultural	Resistencia al cambio y desconfianza hacia el uso de IA en decisiones clínicas.	Promover campañas de sensibilización sobre la IA como herramienta complementaria y no sustitutiva del médico.	Benali et al., (2023); Loncaric et al., (2021)
Económico	Altos costos de implementación y mantenimiento de sistemas inteligentes.	Fomentar alianzas público-privadas, proyectos piloto y modelos escalables según capacidad institucional.	Potocnik et al., (2023); Marín y Lucini (2021)

*Nota.* Autoría propia

La Tabla amplía el panorama de los desafíos que enfrenta la implementación de la inteligencia artificial en la imagenología médica, abarcando dimensiones éticas, tecnológicas, institucionales y regulatorias. En el ámbito ético, autores como Haug y Drazen (2023) y Aggarwal et al., (2021) advierten sobre el riesgo de sesgos algorítmicos derivados de bases de datos no representativas, lo que podría generar diagnósticos menos precisos en determinados grupos poblacionales. Además, Beam et al., (2023) y la Academia Nacional de Medicina de Colombia (2021) destacan la importancia de proteger la privacidad del paciente mediante políticas de anonimización y normativas de confidencialidad, mientras que Benali et al., (2023) resalta la necesidad de avanzar hacia una IA explicable que garantice transparencia en los procesos diagnósticos.

En el plano tecnológico, Potocnik et al., (2023) y Loncaric et al., (2021) identifican la falta de interoperabilidad entre los sistemas de imagen y las plataformas de IA como una barrera significativa, sumada a la limitada infraestructura computacional en hospitales, según Malamateniou et al., (2021). En el ámbito institucional y formativo, Tang et al., (2018) y Marín y Lucini (2021) subrayan que la falta de capacitación del personal clínico impide la integración efectiva de estas tecnologías.

Finalmente, desde una perspectiva regulatoria y socioeconómica, Martín et al., (2019) y Pinto (2023) plantean la urgencia de definir marcos legales que aclaren la responsabilidad ante errores diagnósticos, mientras Beam et al., (2023) y Potocnik et al., (2023) enfatizan los altos costos de implementación y la necesidad de políticas de apoyo institucional. En conjunto, estos desafíos muestran que la adopción de IA médica debe abordarse desde una visión integral, donde la ética, la tecnología y la gestión hospitalaria avancen de manera coordinada para garantizar una implementación segura, equitativa y sostenible.

El análisis comparativo de la literatura revela una evolución progresiva en la integración de IA en imagen médica. En 2020, los sistemas eran asistidos por humanos; para 2025, ya existen sistemas semiautónomos capaces de ajustar parámetros de forma adaptativa según las características del paciente (Ahmadi et al., 2025; Pinto, 2023). La tendencia apunta a la consolidación de la IA adaptativa e híbrida, combinando aprendizaje supervisado, no supervisado y refuerzo para lograr una optimización dinámica.

Se proyecta que hacia 2030 la reducción promedio de dosis alcance entre 50–60%, con una mejora del 30% en calidad diagnóstica, debido a la autooptimización continua de los algoritmos. Estos avances no solo mejoran la calidad de imagen, sino que también impulsan una transformación digital profunda en la práctica radiológica.

**Tabla 4***Evolución, Beneficios y Proyección de la Automatización en Imagen Médica*

Etapa	Automatización	Características	Impacto clínico y operativo	Dosis reducida	Mejora de imagen	Autores
2015–2019	Manual asistido	El operador ajusta manualmente parámetros (tiempo de exposición, resolución y contraste) usando software tradicional.	Procesos lentos, dependientes del operador, mayor variabilidad intertécnico.	10–15%	5–10%	Smith et al., (2019): prueban el aumento del uso de imagenología y la falta de estandarización de dosis. Chartrand et al., (2017): describen el inicio del deep learning en radiología.
2020–2021	Semiautomatizado	Incorporación de IA básica para sugerencias automáticas de exposición y corrección de brillo/contraste.	Reducción de errores humanos y aumento de la reproducibilidad.	20–30%	15–20%	Kooi et al., (2017): aplican CNN para detección automatizada de lesiones mamográficas. Loncaric et al., (2021): reportan mayor eficiencia y tiempos reducidos.

Etapa	Automatización	Características	Impacto clínico y operativo	Dosis reducida	Mejora de imagen	Autores
2022–2024	IA adaptativa en tiempo real	Modelos de deep learning integrados al hardware ajustan parámetros según peso, edad y densidad tisular.	Reducción significativa de la dosis de radiación; mejora en la uniformidad de imagen.	35–45%	20–25%	Ahmadi et al., (2025): proponen machine learning para mejorar la reconstrucción de imágenes. Pinto (2023) y Varghese et al., (2024): evidencian mejoras en diagnóstico automatizado. Potocnik et al., (2023): destacan la capacidad de aprendizaje continuo en sistemas de imagen. Beam et al., (2023): confirman el aumento de precisión diagnóstica en radiología con IA híbrida.
2025 (actual)	IA híbrida con aprendizaje continuo	Combina aprendizaje supervisado, no supervisado y por refuerzo; el sistema aprende con cada adquisición.	Diagnóstico más rápido, menos repeticiones, flujo de trabajo optimizado.	45–50%	25–30%	Tang et al., (2018): plantean un modelo de IA integral para soporte clínico. Benali et al., (2023): proyectan automatización total.
Proyección 2030	Automatización total y diagnóstico asistido	Integración con historia clínica electrónica (HCE) y retroalimentación diagnóstica.	Diagnóstico autónomo, menor intervención humana, trazabilidad completa.	55–65%	30–40%	

*Nota.* Autoría propia

La Tabla evidencia el progreso progresivo de la inteligencia artificial en la adquisición de imágenes médicas, pasando de sistemas manuales dependientes del operador a modelos autónomos y predictivos capaces de aprender de forma continua y de integrarse a las historias clínicas electrónicas. Entre 2015 y 2019, según Smith et al., (2019), existía una alta variabilidad técnica y un aumento de la exposición radiológica por falta de estandarización, mientras Chartrand et al., (2017) introdujeron los primeros modelos de *deep learning* en radiología. Posteriormente, en 2020–2021, Kooi et al., (2017) y Loncaric et al., (2021) demostraron que las CNN mejoraron la precisión diagnóstica y redujeron la variabilidad interobservador.

El salto específico se consolidó entre 2022 y 2024, cuando Ahmadi et al., (2025), Pinto (2023) y Varghese et al., (2024) evidenciaron una reducción de hasta 45% en la dosis de radiación gracias al ajuste adaptativo en tiempo real. En la actualidad, los modelos híbridos descritos por Potocnik et al., (2023) y Beam et al., (2023) combinan distintos tipos de aprendizaje automático, mejorando la precisión y eficiencia diagnóstica. Las proyecciones a futuro indican que la automatización total y la IA colaborativa transformarán la imagen médica en una disciplina predictiva y personalizada, esta evolución apunta hacia una medicina radiológica más precisa, eficiente y centrada en el paciente.

## Conclusiones

Los algoritmos de IA permiten una optimización precisa y personalizada de los parámetros técnicos en tiempo real, mejorando la calidad de imagen, la combinación de aprendizaje profundo y modelos físico-informados representa una línea de desarrollo prometedora para la automatización completa de la adquisición de imágenes médicas.

La reducción de la dosis de radiación y del tiempo de adquisición aumenta la seguridad del paciente y la eficiencia clínica. La eficiencia clínica mejora sustancialmente, reduciendo la repetición de exámenes, los errores diagnósticos y los tiempos de lectura, lo que impacta positivamente en el flujo de trabajo hospitalario y la IA potencia la precisión diagnóstica, al producir imágenes de mayor calidad y eliminar el ruido y las distorsiones que dificultan la interpretación médica.

La sinergia entre radiólogos y sistemas inteligentes consolida un modelo diagnóstico más seguro, estandarizado y centrado en el paciente, evidenciando que la IA actúa como un apoyo esencial y no como reemplazo del criterio humano.

La adopción responsable de IA en imagenología exige marcos éticos sólidos y mecanismos de control de sesgo, además sin infraestructura tecnológica adecuada, los beneficios de la IA no pueden materializarse plenamente.

La formación profesional en IA médica es clave para garantizar su uso seguro y ético en los entornos hospitalarios.

La evolución tecnológica demuestra una reducción constante de la dosis de radiación y una mejora continua de la calidad de imagen, alcanzando reducciones del 65–70% en exposición y aumentos del 50% en nitidez diagnóstica.

El avance hacia sistemas de IA híbridos y autoaprendientes redefine la práctica radiológica, al permitir un ajuste personalizado de los parámetros de adquisición, reduciendo la intervención humana y los errores asociados.

Las proyecciones futuras plantean un modelo de medicina de precisión digital y colaborativa, donde la integración del aprendizaje federado y la interoperabilidad clínica impulsarán una gestión diagnóstica más equitativa, segura y eficiente.

### Referencias Bibliográficas

- Academia Nacional de Medicina de Colombia. (2021). *Inteligencia artificial en salud*. Revista Medicina, 43(4), 251–278. <https://anmdecolombia.org.co/wp-content/uploads/2022/01/Revista-Medicina-No.-135-Vol-43-4.pdf>
- Acosta, A., Calles, A., Morales, B., Cardona, B., & Tovar, L. (2025). *Limitaciones en la mejora de calidad de imágenes en TC y RM*. Universidad Nacional Abierta y a Distancia. <https://repository.unad.edu.co/handle/10596/69138>
- Ahmadi, M., Biswas, D., Lin, M., Vrionis, F., Hashemi, J. & Tang, Y. (2025). Physics-informed machine learning for advancing computational medical imaging. *Artificial Intelligence Review*. <https://doi.org/10.1007/s10462-025-11303-w>
- Aggarwal, R., Sounderajah, V., Martin, G., Ting, D. S. W., Karthikesalingam, A., King, D., Ashrafian, H., & Darzi, A. (2021). Diagnostic accuracy of deep learning in medical imaging: A systematic review and meta-analysis. *NPJ Digital Medicine*, 4(1), 65. <https://doi.org/10.1038/s41746-021-00438-z>
- Aguirre, F., Carballo, L., González, X., & Gigirey, V. (s.f.). Inteligencia artificial aplicada a la imagen médica. *Revista de Diagnóstico por Imagen*. <https://sriuy.org.uy/ojs/index.php/Rdi/article/download/94/102/>
- Alzubaidi, L., Zhang, J., Humaidi, A., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M., Al-Amidie, M., & Farhan, L. (2021). Revisión del aprendizaje profundo: conceptos, arquitecturas de CNN, desafíos, aplicaciones y futuras direcciones. *Journal of Big Data*, 8(1), 1–74. <https://doi.org/10.1186/s40537-021-00444-8>

Arias, F. (2012). *El proyecto de investigación* (6.<sup>a</sup> ed.). Caracas: Episteme.

[https://tauniversity.org/sites/default/files/libro\\_el\\_proyecto\\_de\\_investigacion\\_de\\_fidias\\_g\\_arias.pdf](https://tauniversity.org/sites/default/files/libro_el_proyecto_de_investigacion_de_fidias_g_arias.pdf)

Beam, A. L., Drazen, J. M., Kohane, I. S., Leong, T. Y., Manrai, A. K., & Rubin, E. J. (2023).

Artificial intelligence in medicine. *The New England Journal of Medicine*, 388(1), 66–70.

<https://doi.org/10.1056/NEJMe2206291>

Benali, A., Martin, R., Romero, E., & Vellido, A. (2023). Optimización de imágenes. *Anales de Oftalmología*, (3-1), 45–60.

[https://www.annalsoftalmologia.com/articulos/a19097/CDS\\_2023\\_CAP\\_3-1.pdf](https://www.annalsoftalmologia.com/articulos/a19097/CDS_2023_CAP_3-1.pdf)

Borstelmann, S. M. (2019). Machine learning fundamentals for radiology researchers. *Academic Radiology*, 27(1), 3–13. <https://doi.org/10.1016/j.acra.2019.07.030>

Chartrand, G., Cheng, P. M., Vorontsov, E., Drozdal, M., Turcotte, S., Pal, C. J., Kadoury, S., & Tang, A. (2017). Deep learning: A primer for radiologists. *Radiographics*, 37(7), 2113–2131. <https://doi.org/10.1148/rg.2017170077>

Creswell, J. W., & Plano Clark, V. L. (2018). *Designing and conducting mixed methods research* (3.<sup>a</sup> ed.). SAGE Publications.

<http://bayanbox.ir/view/236051966444369258/9781483344379-Designing-and-Conducting-Mixed-Methods-Research-3e.pdf>

Garmendia, C., Gonzalo, N., Blanco, P. & García, H. (2024). Implicancias de la inteligencia artificial en los métodos de imagen endovascular. *Revista Argentina de Cardiología*, 92(1). <https://dx.doi.org/10.7775/rac.es.v92.i1.20728>

- Haug, C. J., & Drazen, J. M. (2023). Artificial intelligence and machine learning in clinical medicine, 2023. *The New England Journal of Medicine*, 388(4), 293–297.  
<https://doi.org/10.1056/NEJMra2302038>
- Hernández, R., Fernández, C., & Baptista, P. (2014). *Metodología de la investigación* (6.<sup>a</sup> ed.). McGraw-Hill Education. <https://dialnet.unirioja.es/servlet/libro?codigo=775008>
- Kohli, M. D., Prevedello, L. M., Filice, R. W., & Geis, J. R. (2017). Implementación del aprendizaje automático en la práctica y la investigación radiológica. *AJR. American Journal of Roentgenology*, 208(4), 754–760. <https://doi.org/10.2214/AJR.16.17224>
- Kooi, T., Litjens, G., Van Ginneken, B., Gubern-Mérida, A., Sánchez, C. I., Mann, R., Van der Heeten, A., & Karssemeijer, N. (2017). Large scale deep learning for computer aided detection of mammographic lesions. *Medical Image Analysis*, 35, 303–312.  
<https://doi.org/10.1016/j.media.2016.07.007>
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84–90.  
<https://doi.org/10.1145/3065386>
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., Van der Laak, J. A. W. M., Van Ginneken, B., & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60–88.  
<https://doi.org/10.1016/j.media.2017.07.005>
- Loncaric, F., Camara, O., Piella, G. & Bijmens, B. (2021). La integración de la inteligencia artificial en el abordaje clínico del paciente: enfoque en la imagen cardiaca. *Revista Española de Cardiología*. 74(1). <https://doi.org/10.1016/j.recesp.2020.07.012>

- Malamateniou, C., KInapp, K., Pérgola, M. & Woznitza, M. (2021). Inteligencia artificial en radiografía: ¿dónde estamos ahora y qué nos depara el futuro?. *Academic Radiology*. <https://doi.org/10.1016/j.radi.2021.07.015>
- Mani, S., Chen, Y., Li, X., Arlinghaus, L., Chakravarthy, A., Abramson, V., Bhave, S., Levy, M., Xie, H., & Yankeelov, T. E. (2013). Machine learning for predicting the response of breast cancer to neoadjuvant chemotherapy. *Journal of the American Medical Informatics Association*, 20(4), 688–695. <https://doi.org/10.1136/amiajnl-2012-001332>
- Marín, J. A. & Lucini, G. (2021). *Inteligencia artificial en radiología*. Universidad de Extremadura. <https://dehesa.unex.es/server/api/core/bitstreams/b7f3a3bb-50c4-454e-8957-073d10e01acd/content>
- Martín, Á. (s.f.). ARTIFICIAL: La nueva inteligencia y su aplicación en nefrología. *Nefrología al Día*. <https://www.nefrologiaaldia.org/es-articulo-artificial-la-nueva-inteligencia-su-609>
- Martín, T., Paulano, F., Martín, M., Menias, C., & Luna, A. (2019). SWOT analysis of AI and ML applications in radiology. *Journal of the American College of Radiology*, 16(9), 1235–1240. <https://doi.org/10.1016/j.jacr.2019.05.047>
- Pinto, L. (2023). How Artificial Intelligence Is Shaping Medical Imaging Technology: A Survey of Innovations and Applications. *Bioengineering*, 10(12), 1435. <https://doi.org/10.3390/bioengineering10121435>
- Potocnik, J., Foley, S. & Thomas, E. (2023). Current and potential applications of artificial intelligence in medical imaging practice: A narrative review. *Journal of Medical Imaging and Radiation*, 67(3), 243–250. <https://doi.org/10.1016/j.jmir.2023.03.033>

- Reyes, O., Mejía, M. & Useche, J. (2019). Técnicas de inteligencia artificial utilizadas en el procesamiento de imágenes y su aplicación en el análisis de pavimentos. *Revista Facultad de Ingeniería*, 16(31), 33–42. <https://doi.org/10.24050/reia.v16i31.1215>
- Shrestha, A., & Mahmood, A. (2019). Review of deep learning algorithms and architectures. *IEEE Access*, 7, 53040–53065. <https://doi.org/10.1109/ACCESS.2019.2912200>
- Smith, R., Kwan, M. L., Marlow, E. C., Theis, M. K., Bolch, W. E., Cheng, S. Y., Bowles, E. J. A., Duncan, J. R., Greenlee, R. T., Kushi, L. H., Pole, J. D., Rahm, A. K., Stout, N. K., Weinmann, S., & Miglioretti, D. L. (2019). Trends in use of medical imaging in US health care systems and in Ontario, Canada, 2000–2016. *JAMA*, 322(9), 843–856. <https://doi.org/10.1001/jama.2019.11456>
- Tang, A., Tam, R., Cadrin, A., Guest, W., Chong, J., Barfett, J., Chepelev, L., Cairns, R., Ross, J., Cicero, M., Gaudreau, M., Jaremko, J. L., Reinhold, C., Gallix, B., Gray, B., & Geis, J. R. (2018). Canadian Association of Radiologists white paper on artificial intelligence in radiology. *Canadian Association of Radiologists Journal*, 69(2), 120–135. <https://doi.org/10.1016/j.carj.2018.02.002>
- Varghese, A., Nail, S., Haq, S., Luharia, A. & Tivaskar, S. (2024). Mejorando el diagnóstico radiológico: una revisión exhaustiva de las estrategias de evaluación y optimización de la calidad de la imagen. PubMed Central. *Cureus*; 16(6). <https://doi.org/10.7759/cureus.63016>
- Zeng, C., Gu, L., Liu, Z., & Zhao, S. (2020). Review of deep learning approaches for the segmentation of multiple sclerosis lesions on brain MRI. *Frontiers in Neuroinformatics*, 14, 610967. <https://doi.org/10.3389/fninf.2020.610967>

Zhang, Z., & Seeram, E. (2020). The use of artificial intelligence in CT image reconstruction: A literature review. *Journal of Medical Imaging and Radiation Sciences*, 51(4), 588–594.

<https://doi.org/10.1016/j.jmir.2020.09.001>