

**Detección automática utilizando redes neuronales para identificar y corregir
artefactos en imágenes médicas, mejorando la precisión diagnóstica**

Camilo Andrés Carvajal Ospina

Juan Pablo Rivera

Julián Camilo Giraldo Tovar

Paula Daniela Saavedra

Stiven Alexander González Turriago

Asesor

Edna Rocío Jamaica

Universidad Nacional Abierta y a Distancia UNAD

Escuela de Ciencias de la salud

Tecnología en Radiología e Imágenes Diagnósticas

2025

Agradecimientos

Agradecemos primero a Dios, por guiarnos y darnos sabiduría y perseverancia para alcanzar la culminación de este diplomado con éxito.

A nuestras familias y amigos, por su apoyo incondicional, acompañamiento y palabras de aliento en cada etapa de este proceso académico.

A la UNAD, por entregar herramientas educativas que hicieron posible nuestro desarrollo personal y profesional.

Expresamos nuestra gratitud a los tutores y docentes, por su orientación, paciencia y conocimientos, que nos guiaron en la realización de este trabajo.

También agradecemos a todas las personas que contribuyeron a la realización de este proyecto

Y por supuesto, a nosotros: Camilo Andrés Carvajal Ospina, Juan Pablo Rivera, Julián Camilo Giraldo Tovar, Paula Daniela Saavedra y Stiven Alexander González Turriago, quienes trabajamos de manera conjunta y comprometida para alcanzar los objetivos.

Dedicatoria

Este trabajo está dedicado a nuestras familias y seres queridos, quienes con su apoyo, paciencia y comprensión nos brindaron la motivación necesaria para culminar este diplomado.

También lo dedicamos a nuestros compañeros de grupo, quienes con colaboración, compromiso y espíritu de equipo hicieron posible el aprendizaje compartido y el crecimiento profesional durante el desarrollo de este proyecto sobre detección automática de artefactos utilizando redes neuronales.

Resumen

La presencia de artefactos en imágenes médicas, como las generadas por resonancia magnética (RM) y tomografía computarizada (TC), constituye un desafío para la precisión diagnóstica, al introducir distorsiones que pueden comprometer la interpretación clínica y la toma de decisiones. Estos artefactos pueden originarse por movimiento del paciente, fallos técnicos o interferencias externas, afectando directamente la calidad visual y el flujo de trabajo clínico. En respuesta a esta problemática, la IA, especialmente a través de redes neuronales artificiales (ANN) y convolucionales (CNN), surge como una alternativa innovadora para la detección y corrección automática de estos defectos visuales. Este estudio, de enfoque cualitativo, analiza el impacto técnico, clínico y ético de la aplicación de estas tecnologías en el procesamiento de imágenes médicas. La investigación incluye una revisión documental y el análisis de arquitecturas como U-Net, utilizadas en segmentación y mejora de imágenes biomédicas. Los hallazgos sugieren que las redes neuronales superan a los métodos tradicionales en precisión, velocidad y automatización, permitiendo una mejora significativa en la calidad diagnóstica, al tiempo que optimizan procesos mediante su integración con sistemas PACS inteligentes. Sin embargo, persisten desafíos relacionados con la explicabilidad algorítmica, la interoperabilidad con sistemas clínicos, la capacitación del personal y la garantía de equidad y protección de datos del paciente. En conclusión, la implementación responsable de redes neuronales en imagenología médica representa una oportunidad transformadora para avanzar hacia una medicina más precisa, automatizada, ética y centrada en el paciente.

Palabras clave: Inteligencia Artificial, Redes Neuronales, Artefactos, Diagnóstico Automático, Aprendizaje Profundo, Ética Médica, U-Net.

Abstract

The presence of artifacts in medical images, such as those generated by magnetic resonance imaging (MRI) and computed tomography (CT), poses a significant challenge to diagnostic accuracy by introducing distortions that can compromise clinical interpretation and decision-making. These artifacts may result from patient movement, technical failures, or external interferences, directly affecting image quality and clinical workflow. In response to this issue, artificial intelligence (AI), particularly through artificial neural networks (ANN) and convolutional neural networks (CNN), emerges as an innovative solution for the automatic detection and correction of these visual defects. This qualitative study analyzes the technical, clinical, and ethical implications of applying these technologies to medical image processing. The research includes a literature review and an analysis of neural architectures such as U-Net, widely used in biomedical image segmentation and enhancement. Findings suggest that neural networks outperform traditional methods in terms of accuracy, speed, and automation, enabling significant improvements in diagnostic quality while optimizing processes through integration with intelligent PACS systems. However, challenges remain regarding algorithm transparency, clinical system interoperability, staff training, and the assurance of equity and patient data protection. In conclusion, the responsible implementation of neural networks in medical imaging represents a transformative opportunity to advance toward more precise, automated, ethical, and patient-centered medicine.

Keywords: Artificial Intelligence, Neural Networks, Artifacts, Automatic Diagnosis, Deep Learning, Medical Ethics, U-Net.

Tabla de Contenido

Introducción	11
Planteamiento del Problema	15
Justificación	17
Objetivos.....	19
Objetivo General.....	19
Objetivo Específicos	19
Marco Teórico	20
Inteligencia Artificial (IA)	20
<i>Generalidades</i>	20
<i>Usos Principales</i>	21
<i>Ventajas y Desventajas</i>	22
Tomografía Computarizada (TC)	22
<i>Generalidades</i>	22
<i>Principios Físicos</i>	23
<i>Avances Tecnológicos</i>	23
Artefactos en Tomografía Computarizada	23
<i>Generalidades</i>	23
<i>Tipos de Artefactos</i>	24
<i>Técnicas Manuales de Corrección</i>	24

Corrección de Artefactos en TC mediante Inteligencia Artificial.....	24
Generalidades	24
<i>Tipos de Algoritmos y su Funcionamiento</i>	25
<i>Ventajas y Desventajas</i>	27
Redes Neuronales y Procesamiento de Imágenes Médicas	28
<i>Funciones Principales</i>	28
<i>Aplicaciones Clínicas</i>	29
Integración de IA en los Sistemas Clínicos	30
<i>Impacto en el Flujo de Trabajo</i>	30
<i>Retos en la Implementación</i>	31
Retos Éticos y Consideraciones en el Uso de IA Médica.....	31
<i>Privacidad de datos</i>	31
<i>Transparencia y Explicabilidad</i>	32
<i>Evitar Sesgos</i>	32
Marco Metodológico.....	34
Enfoque y Tipo de Investigación	34
Diseño de Investigación	34
Muestra	34
Técnicas e Instrumentos de Recolección de Datos	35
Análisis de la Información	35

Fases de la Investigación.....	36
Presentación de Resultados.....	37
Conclusiones.....	51
Referencias Bibliográficas	54

Lista de Tablas

Tabla 1 <i>Fases De La Investigación</i>	36
Tabla 2 <i>Precisión En La Detección De Artefactos Según Tipo De Red Utilizada</i>	38
Tabla 3 <i>Mejora De La Calidad De Imagen Según Modalidad Y Red Neuronal Utilizada..</i>	40
Tabla 4 <i>Eficiencia Operativa Y Reducción De Tiempos De Análisis</i>	43
Tabla 5 <i>Percepciones Profesionales Sobre Ventajas Y Limitaciones</i>	45
Tabla 6 <i>Reducción De Dosis Y Mantenimiento De Calidad Diagnóstica Con Uso De CNN</i>	47
Tabla 7 <i>Cuadro Comparativo Sobre Aplicaciones De Redes Neuronales Convolucionales</i> <i>(CNN) En Imágenes Médicas</i>	49

Lista de Gráficas

Gráfica 1 *Mejora Porcentual De La Calidad Diagnóstica*.....47

Introducción

Las imágenes médicas, como la tomografía computarizada (TC) y la resonancia magnética (RM), constituyen herramientas fundamentales para el diagnóstico clínico moderno. Sin embargo, su calidad puede verse afectada por la presencia de artefactos originados por movimiento del paciente, fallos técnicos, interferencias externas o limitaciones del equipo. Estos defectos visuales no solo distorsionan la información anatómica y funcional, sino que también pueden comprometer la precisión diagnóstica, generando falsos positivos o falsos negativos que impactan directamente en la toma de decisiones médicas y en la seguridad del paciente.

Este estudio contribuye al cuerpo de conocimiento sobre la aplicación de redes neuronales en la detección de artefactos, un campo en rápido crecimiento, pero aún poco explorado en el ámbito hispanoamericano: ofrece un análisis detallado de los tipos de artefactos más frecuentes y su impacto real en la degradación de las imágenes médicas. Integra evidencia de múltiples arquitecturas neuronales, como ANN, CNN y U-Net, identificando sus fortalezas y limitaciones específicas en contextos clínicos y aporta una visión comparativa entre métodos tradicionales de corrección de artefactos y técnicas basadas en IA, enriqueciendo la discusión con fundamentos teóricos y estudios recientes.

La reducción y corrección de artefactos ha sido históricamente un desafío técnico, requerido tanto para mejorar la claridad visual de las imágenes como para optimizar el flujo de trabajo clínico. Aunque existen métodos tradicionales de filtrado y postprocesamiento, estos son limitados y a menudo insuficientes. En este contexto, los avances recientes en inteligencia artificial (IA), especialmente en redes neuronales artificiales (ANN) y convolucionales (CNN), han introducido nuevas posibilidades para automatizar la

detección y corrección de artefactos con niveles de precisión superiores a los métodos convencionales.

Este trabajo revisa y describe cómo las redes neuronales pueden automatizar procesos que históricamente dependían del criterio humano. Los aportes tecnológicos incluyen: evidencias de que las CNN pueden detectar patrones invisibles al ojo humano, logrando identificar artefactos con mayor precisión. Mostrar cómo sistemas basados en IA pueden integrarse a los PACS, acelerando el flujo de trabajo y señalar la evolución de arquitecturas como U-Net y su capacidad para reconstruir imágenes más limpias, incluso a partir de datos ruidosos.

Modelos como U-Net y sus variantes han demostrado un rendimiento notable en tareas de segmentación, reconstrucción y mejora de imágenes biomédicas. Su capacidad para identificar patrones complejos y distinguir artefactos del tejido anatómico las posiciona como herramientas prometedoras para apoyar el diagnóstico por imágenes. Las redes neuronales no solo pueden detectar los artefactos, sino también corregirlos automáticamente, integrarse con sistemas PACS inteligentes y optimizar tiempos de interpretación, lo que abre un camino hacia una imagenología más automatizada, eficiente y confiable.

Los resultados del estudio revelan beneficios directos en el entorno hospitalario: reducción en diagnósticos erróneos causados por artefactos. Disminución del número de estudios repetidos, lo que reduce radiación, costos y tiempo. Mejora de la precisión diagnóstica y, por ende, de la seguridad del paciente y Optimización del tiempo del personal médico, al disminuir la revisión manual de imágenes deterioradas.

A pesar del potencial que tienen las redes neuronales en la mejora de la calidad diagnóstica y la optimización de procesos en imagenología médica, su adopción en la

práctica clínica sigue siendo limitada. Esto se debe a múltiples factores interrelacionados que van más allá de la mera disponibilidad tecnológica. En primer lugar, la necesidad de bases de datos extensas, diversificadas y etiquetadas correctamente constituye un obstáculo crítico, ya que la eficacia de los modelos de IA depende directamente de la calidad y cantidad de datos con los que se entrenan. Además, los procesos de entrenamiento de estas redes son complejos y requieren recursos computacionales avanzados, lo que puede restringir su implementación en instituciones con infraestructura limitada.

A esto se suma el desafío de la interoperabilidad: integrar sistemas de IA con los actuales PACS, RIS y otros sistemas hospitalarios no siempre es trivial, y requiere coordinación técnica y estándares comunes para asegurar un flujo de trabajo eficiente. Los aspectos regulatorios y éticos, como las políticas de protección de datos y la necesidad de garantizar la privacidad del paciente, representan otra barrera importante, especialmente en contextos donde las normativas son estrictas o poco claras. En conjunto, estos factores evidencian la existencia de una brecha significativa entre el desarrollo tecnológico y su aplicación real en entornos clínicos, subrayando la necesidad de estrategias integrales que incluyan formación, infraestructura, regulación y validación clínica para facilitar la adopción responsable y efectiva de redes neuronales en la práctica médica diaria.

Ante esta situación, es necesario analizar de manera profunda, técnica y cualitativa el potencial real de las redes neuronales para la detección automática de artefactos, así como las percepciones de los profesionales de imagenología sobre sus ventajas, limitaciones, desafíos éticos y aplicabilidad clínica. La comprensión de estos aspectos es fundamental para garantizar que la implementación de estas herramientas no solo sea técnicamente eficaz, sino también segura, ética y alineada con las necesidades clínicas.

Asimismo, es crucial evaluar los retos asociados a la explicabilidad de los algoritmos, la integración con los sistemas hospitalarios existentes, la protección de datos del paciente y la capacitación del personal médico, ya que estos factores determinan en gran medida la aceptación y el uso efectivo de la tecnología en entornos reales. Analizar las percepciones de los profesionales permite identificar barreras y oportunidades, generando información valiosa para diseñar estrategias de adopción que optimicen la calidad diagnóstica, reduzcan los errores clínicos y mejoren la eficiencia operativa. En este contexto, el estudio de la aplicación de redes neuronales en la detección y corrección de artefactos se convierte en un paso fundamental para avanzar hacia una medicina más precisa, automatizada, ética y centrada en el paciente, en la que la inteligencia artificial funcione como un apoyo confiable para los profesionales de la salud, potenciando su capacidad de decisión y contribuyendo a la excelencia en la atención médica.

Planteamiento del Problema

A pesar del avance tecnológico, la persistencia de artefactos en imágenes médicas representa un desafío clínico significativo, ya que puede conducir a diagnósticos incorrectos o imprecisos. La falta de sistemas automatizados que identifiquen y corrijan estos artefactos obliga al personal médico a una revisión manual extensa, aumentando el tiempo y los costos asociados al proceso diagnóstico (Robayo, 2024).

No obstante, que el avance tecnológico ha desarrollado modelos de redes neuronales para la detección automática de artefactos, su integración en la práctica clínica es limitada. Esto se debe a la complejidad de entrenar estos sistemas con bases de datos extensas y variadas, y a la necesidad de validar su efectividad en distintos tipos de imágenes médicas, lo que impide su adopción generalizada (Hosny et al., 2018).

Uno de los problemas más comunes, es la presencia de artefactos en imágenes médicas, que afectan la calidad visual, además de interferir directamente en la interpretación clínica, generando falsos positivos o negativos que impactan negativamente en la toma de decisiones médicas (Giacconi, 2021). Por tanto, reducir la interferencia de estos artefactos es fundamental para mejorar la fiabilidad del diagnóstico y, en consecuencia, la atención al paciente.

Las dificultades técnicas y organizativas para desarrollar, implementar e integrar soluciones automáticas basadas en redes neuronales dificultan su adopción en la rutina clínica, limitando el impacto positivo que podrían tener en la mejora de la calidad de las imágenes y en la precisión diagnóstica (Gil et al., 2023). Esta complejidad limita la incorporación rutinaria de estas herramientas en el entorno clínico, frenando el potencial impacto positivo que podrían tener en la mejora de la calidad de las imágenes y la precisión diagnóstica.

El desarrollo de un sistema eficiente de detección y corrección automática de artefactos basado en redes neuronales podría revolucionar la imagen médica, Estos sistemas pueden mejorar la precisión diagnóstica, optimizar los tiempos de interpretación y, en última instancia, mejorar los resultados clínicos. Sin embargo, su implementación exitosa requiere superar desafíos técnicos, operacionales y éticos. Es esencial abordar estos obstáculos mediante una combinación de innovación tecnológica, formación adecuada de los profesionales de la salud y una regulación normativa que garantice la seguridad y eficacia de estas herramientas en la práctica clínica diaria (Belzunce, 2024).

En este contexto, surge la pregunta problema ¿Qué ventajas y limitaciones perciben en el uso de redes neuronales para la detección automática de artefactos en imágenes médicas, y cómo creen que esta tecnología puede transformar la práctica diagnóstica en sus especialidades?

Justificación

Las imágenes médicas son herramientas clave en la detección y seguimiento de enfermedades, pero frecuentemente se ven afectadas por artefactos, que son distorsiones o fallas visuales originadas por el movimiento del paciente, interferencias o problemas técnicos (Gil et al., 2023). Estos artefactos pueden disminuir la calidad de la imagen, lo que afecta la interpretación clínica y pone en riesgo la precisión diagnóstica, incrementando la posibilidad de errores y retrasos en el tratamiento, afectando tanto al paciente como al sistema de salud.

La inteligencia artificial, y en particular las redes neuronales profundas, han demostrado un gran potencial para analizar imágenes médicas, identificando patrones complejos que pueden no ser evidentes para el ojo humano (Martí, 2024). Estas tecnologías permiten el desarrollo de algoritmos capaces de detectar y clasificar artefactos automáticamente, mejorando la calidad de las imágenes y facilitando un diagnóstico más preciso y eficiente, su implementación podría ser un cambio significativo en la práctica, logrando una evaluación más rápida y precisa en los estudios.

Hoy en día, la identificación y corrección manual de artefactos es una tarea laboriosa y que puede provocar errores humanos, que generan retrasos en el proceso diagnóstico y puede aumentar los costos hospitalarios. La carencia de herramientas tecnológicas automáticas eficientes limita la optimización del flujo de trabajo en radiología y otras áreas clínicas (Anales de la ICRP, 2024).

La implementación práctica de las redes neuronales para detectar artefactos tiene retos como la diversidad y complejidad de los tipos de artefactos, la necesidad de grandes conjuntos de datos anotados para el entrenamiento, y la integración con los sistemas

hospitalarios existentes (Campus HealthTech, 2025), entonces superar estos obstáculos es crucial para garantizar un sistema confiable y útil en entornos clínicos reales.

El desarrollo de sistemas automatizados basados en IA para la detección y corrección de artefactos puede transformar la práctica diagnóstica, al reducir errores, agilizar la interpretación y mejorar los resultados clínicos (Belzunce, 2024). Sin embargo, es fundamental evaluar su eficacia real y garantizar que complementen, y no reemplacen, la supervisión médica.

El propósito de esta investigación es identificar cómo un sistema automatizado basado en inteligencia artificial para la detección de artefactos en imágenes médicas puede mejorar la calidad diagnóstica, reducir la carga de trabajo manual, minimizar los errores humanos y optimizar los recursos técnicos y clínicos, además está orientada a beneficiar a los pacientes, al evitar la repetición innecesaria de estudios, reducir la exposición a radiación ionizante y mejorar la oportunidad en el acceso a un diagnóstico oportuno. Así mismo, favorece a los profesionales de la salud, al proporcionar herramientas de apoyo basadas en inteligencia artificial que optimizan la interpretación de las imágenes médicas, disminuyen la carga operativa y reducen el margen de error humano y, por último, a las instituciones clínicas pues se minimizan los costos, se agilizan los tiempos y se elevan los estándares de calidad en la atención diagnóstica, promoviendo un uso más eficiente de los recursos tecnológicos y humanos.

Objetivos

Objetivo General

Analizar el potencial de las redes neuronales artificiales, especialmente las convolucionales (CNN), para la detección y corrección automática de artefactos en imágenes médicas (TC y RM), evaluando su aplicabilidad clínica, impacto en la precisión diagnóstica y los desafíos técnicos, éticos y operativos asociados a su implementación.

Objetivo Específicos

Identificar los tipos de artefactos más frecuentes en imágenes médicas y su impacto en la calidad diagnóstica y la interpretación clínica.

Comparar el funcionamiento técnico y la eficacia de las redes neuronales artificiales y convolucionales, como U-Net, en la detección y corrección automática de artefactos en imágenes de tomografía computarizada (TC) y resonancia magnética (RM).

Analizar mediante literatura, las percepciones de profesionales en imagenología respecto a las ventajas, limitaciones y consideraciones éticas del uso de inteligencia artificial en el diagnóstico por imágenes.

Marco Teórico

Los artefactos en imágenes médicas son alteraciones que afectan la calidad de las imágenes y pueden comprometer la precisión del diagnóstico y pueden surgir por múltiples razones, como errores en la adquisición, movimientos del paciente, presencia de objetos metálicos o limitaciones del equipo. La identificación y corrección oportuna de estos artefactos es esencial para evitar interpretaciones erróneas y mejorar la eficiencia diagnóstica, la detección temprana de artefactos es clave para evitar errores diagnósticos que puedan derivarse de una mala interpretación de las imágenes (García et al., 2024).

El análisis y la interpretación precisa de las imágenes médicas son fundamentales para el diagnóstico y tratamiento efectivo de diversas enfermedades, sin embargo, la presencia de artefactos en estas imágenes representa un obstáculo importante que puede afectar la calidad visual y la confiabilidad del diagnóstico clínico.

En los últimos años, el avance de la inteligencia artificial, particularmente a través de redes neuronales, ha abierto nuevas posibilidades para la detección y corrección automática de estos artefactos, ofreciendo potenciales mejoras en la precisión diagnóstica y en la eficiencia del flujo de trabajo médico. Este marco teórico explora los fundamentos tecnológicos, las aplicaciones clínicas, las ventajas, limitaciones y desafíos relacionados con el uso de redes neuronales en la optimización de imágenes médicas, sentando las bases para comprender su impacto actual y futuro en la práctica médica.

Inteligencia Artificial (IA)

Generalidades. La inteligencia artificial (IA) comprende sistemas computacionales capaces de imitar funciones cognitivas humanas como el aprendizaje, el razonamiento y la resolución de problemas. En el ámbito de la salud, ha revolucionado el análisis de imágenes médicas, permitiendo una evaluación más precisa y rápida de los estudios radiológicos La

introducción de la IA en la medicina ha generado importantes avances en la automatización del diagnóstico, sobre todo mediante el análisis computacional de imágenes médicas. A este respecto, Machacado y Aparicio (2021) ofrecen una visión integral de las técnicas de IA aplicadas al diagnóstico por imágenes, explicando cómo estas tecnologías permiten analizar grandes volúmenes de datos visuales, detectar estructuras relevantes y reducir errores humanos.

Según Alzubaidi et al., (2021), la inteligencia artificial (IA) se refiere a la capacidad de los sistemas computacionales para aprender, razonar y tomar decisiones a partir de grandes volúmenes de datos, imitando procesos cognitivos humanos mediante algoritmos avanzados, especialmente a través del aprendizaje profundo y las redes neuronales convolucionales (CNN), asimismo Anwar et al. (2018) destacan que la IA aplicada en el análisis de imágenes permite la automatización de tareas complejas como la clasificación, segmentación y corrección de artefactos, mejorando la precisión diagnóstica. Además, Arroyave et al. (2025) señalan que la integración de IA en tecnologías como la tomografía computarizada ha revolucionado la calidad de las imágenes médicas, facilitando procesos más rápidos y eficientes.

Además, Andersson et al. (2016) ilustran que la IA contribuye en la corrección automática de distorsiones y movimientos en imágenes de resonancia magnética, mostrando su potencial para optimizar la interpretación clínica.

En conjunto, estos autores coinciden en que la inteligencia artificial representa una herramienta poderosa y en constante evolución que transforma la práctica médica mediante la mejora de la calidad y el análisis de imágenes.

Usos Principales. En diagnóstico por imágenes la IA permite la detección automática de anomalías y artefactos, la segmentación de estructuras anatómicas, la

clasificación de patologías y la corrección de errores como los artefactos (Guzmán et al., s.f.).

A su vez, Guzmán et al., (s.f.) complementan al demostrar que la IA no solo permite clasificar imágenes médicas, sino también identificar y corregir artefactos, optimizando la precisión diagnóstica al filtrar elementos visuales no deseados.

También, Machacado y Aparicio (2021) exponen que la integración de IA en el análisis de imágenes diagnósticas ha permitido el desarrollo de sistemas capaces de asistir en la interpretación mediante la detección automática de estructuras, anomalías y errores técnicos, incluyendo artefactos, con mayor precisión y eficiencia en el diagnóstico.

Ventajas y Desventajas. Dentro de las ventajas se encuentran la reducción del error humano, la agilización del diagnóstico y un mejor aprovechamiento de los datos clínicos y en las desventajas están los riesgos de sesgos algorítmicos, la necesidad de grandes volúmenes de datos etiquetados y los problemas de explicabilidad y confianza clínica (Farhud y Zokaei, 2021).

Así mismo, London (2019) plantea la tensión entre precisión diagnóstica y explicabilidad de los sistemas de cajas negras, ya que en medicina no basta con que un sistema sea preciso; debe ser comprensible para generar confianza clínica y permitir decisiones informadas. Además, Vayena et al., (2018) subrayan la importancia de auditar los algoritmos y mantener procesos transparentes en el entrenamiento y validación de modelos basados en machine learning para aplicaciones médicas.

Tomografía Computarizada (TC)

Generalidades. La TC es una técnica de imagen médica que utiliza rayos X y procesamiento computarizado para obtener imágenes detalladas del interior del cuerpo, es ampliamente utilizada en diagnóstico neurológico, oncológico y traumatológico. Con el

avance de la tecnología en imagenología, la Tomografía Computarizada y la Resonancia Magnética han permitido diagnósticos más precisos, sin embargo, las dos están sujetas a la presencia de artefactos que degradan su calidad (Calzado y Geleijns, 2010).

Principios Físicos. Se basa en la atenuación diferencial de los rayos X al atravesar distintos tejidos. Los detectores captan la señal y un software la reconstruye en cortes axiales, coronales o sagitales.

Avances Tecnológicos. Los avances han mejorado la calidad de imagen, reducido la dosis de radiación e incorporado algoritmos de reconstrucción más eficientes. Sin embargo, persisten limitaciones como los artefactos por movimiento o metal (Chen et al., 2021).

Artefactos en Tomografía Computarizada

Generalidades. Los artefactos son distorsiones que degradan la imagen diagnóstica. Su origen puede ser técnico, del paciente o del entorno. Su presencia puede afectar negativamente la interpretación clínica (García et al., 2024).

Según Alzubaidi et al., (2021), la complejidad de los datos generados por equipos de TC hace que las imágenes sean susceptibles a múltiples tipos de artefactos, que pueden originarse por factores técnicos como calibración deficiente, movimiento del paciente o interferencias externas.

Andersson et al., (2016) subrayan que, en modalidades avanzadas como la resonancia magnética y la TC, los artefactos pueden producir distorsiones significativas que dificultan la visualización precisa de estructuras anatómicas, lo que representa un desafío para el diagnóstico.

También, Arroyave et al., (2025) refuerzan esta perspectiva al señalar que la incorporación de modelos inteligentes en los sistemas de TC ha mostrado un impacto positivo en la reducción de artefactos y en la optimización del proceso diagnóstico,

evidenciando el potencial transformador de la inteligencia artificial en la práctica radiológica.

Tipos de Artefactos. Los artefactos en tomografía computarizada pueden clasificarse en diferentes tipos según su origen. Los artefactos por movimiento ocurren cuando el paciente se desplaza durante la adquisición de la imagen, generando distorsiones que afectan la nitidez y dificultan la interpretación diagnóstica. Por otro lado, los artefactos metálicos se producen por la presencia de cuerpos metálicos en el campo de imagen, como implantes o prótesis, los cuales generan líneas o distorsiones brillantes debido a la alta atenuación del metal. También se presentan artefactos por mal calibrado del equipo, derivados de errores técnicos en los parámetros de adquisición o desajustes del detector, lo que puede provocar imágenes inconsistentes o con ruido. Finalmente, los artefactos en la reconstrucción de imagen surgen durante el procesamiento computacional de los datos tomográficos, cuando se aplican algoritmos incorrectos o hay pérdida de información, lo que compromete la fidelidad de la imagen final (Andersson et al., 2016). Estos artefactos, si no se detectan y corrigen adecuadamente, pueden llevar a diagnósticos erróneos o retrasos en el tratamiento del paciente.

Técnicas Manuales de Corrección. Actualmente, muchas correcciones dependen del criterio del operador: repetir estudios, cambiar parámetros o usar filtros específicos. Esto puede generar sobrecarga operativa, demoras y aumento innecesario de dosis al paciente (Oliveros et al., 2024).

Corrección de Artefactos en TC mediante Inteligencia Artificial

Generalidades. La IA ha permitido automatizar la identificación y corrección de artefactos, facilitando diagnósticos más precisos y eficientes. Esta tecnología representa un avance hacia sistemas de imagenología más autónomos y seguros (Belzunce, 2024).

Según Alzubaidi et al., (2021), los modelos de aprendizaje profundo, especialmente las redes neuronales convolucionales (CNN), han demostrado una gran capacidad para identificar patrones complejos y corregir distorsiones en las imágenes médicas, superando las limitaciones de los métodos tradicionales.

Además, Andersson et al., (2016) destacan que estas tecnologías permiten mitigar problemas derivados del movimiento y las distorsiones geométricas, mejorando la calidad visual y la fidelidad de la imagen reconstruida.

Por su parte, Arroyave et al., (2025) subraya que la integración de sistemas basados en IA en equipos de TC representa un avance hacia una imagenología más autónoma, segura y confiable, marcando un camino hacia la mejora continua en la práctica clínica y el cuidado del paciente.

Tipos de Algoritmos y su Funcionamiento

Redes Neuronales Convolucionales (CNN). Las CNN son una variación especializada de las ANN, diseñadas para el análisis de imágenes, utilizan filtros convolucionales que permiten extraer características espaciales jerárquicas (bordes, texturas, formas) con alta precisión (Lubinus et al., 2025). Esta capacidad es especialmente útil para identificar artefactos, ya que estos suelen presentar patrones visuales repetitivos o anómalos que pueden ser detectados automáticamente. Asimismo, Anwar et al., (2018) también destacan su aplicabilidad transversal en modalidades como TC, RM, ecografía y radiografía, haciendo de estas redes una solución escalable.

Las CNN son una arquitectura especializada dentro del Deep learning, desarrollada para procesar datos en forma de imágenes, su diseño permite aprender características visuales como bordes, formas y texturas, lo que las hace especialmente útiles en contextos clínicos donde es necesario detectar artefactos que distorsionan la imagen médica.

Entre las tecnologías más utilizadas se destacan las redes neuronales convolucionales (CNN), que están diseñadas para el procesamiento de datos en forma de imágenes y son capaces de aprender patrones espaciales y texturales complejos, lo que las hace ideales para tareas como la detección automática de artefactos en radiografías, tomografías y resonancias.

De esta forma, Yu et al., (2021) realizaron una revisión sobre el uso de CNN en imágenes médicas, destacando su capacidad para realizar detección de anomalías, segmentación de tejidos y reducción de artefactos, superando a otros métodos tradicionales en precisión y velocidad. Asimismo, Gu et al., (2018) profundizaron en los avances técnicos en CNN, como en las redes residuales o modelos de múltiples capas, que permiten una mejor detección de irregularidades sutiles, como los artefactos generados por movimiento, metal o fallas técnicas.

Las redes neuronales artificiales (ANN) y las redes neuronales convolucionales (CNN) han mostrado una alta capacidad para aprender patrones complejos en grandes volúmenes de datos, como los de las imágenes médicas. Estas redes son eficaces en segmentación, clasificación y detección de anomalías visuales (Decuyper et al., 2021), así mismo las redes neuronales convolucionales han sido fundamentales para el desarrollo de sistemas capaces de reconocer patologías con alta precisión, superando en algunos casos el desempeño humano en tareas específicas (Chen et al., 2021). En la detección de artefactos, estas redes pueden entrenarse para identificar patrones anómalos que corresponden a interferencias visuales no fisiológicas y posteriormente corregirlas o marcarlas para revisión.

Redes Tipo U-Net. Las redes neuronales tipo U-Net han emergido como una arquitectura especialmente eficaz para la segmentación precisa de áreas afectadas por

artefactos en imágenes médicas. Según Ronneberger et al., (2015) estas redes convolucionales están diseñadas para capturar tanto características locales como globales de la imagen, lo que les permite identificar con gran exactitud las regiones distorsionadas o degradadas. Su estructura simétrica en forma de U facilita la recuperación de detalles espaciales durante el proceso de segmentación, haciendo posible distinguir entre tejidos sanos y áreas comprometidas por artefactos. La aplicación de U-Net en la corrección automática de artefactos contribuye significativamente a mejorar la calidad de las imágenes médicas y, por ende, la precisión diagnóstica, consolidándose como una herramienta fundamental dentro de los avances en inteligencia artificial para imagenología clínica.

Redes Residuales y DenseNet. Las redes residuales (ResNet) y las redes densas (DenseNet) representan avances significativos en el diseño de arquitecturas de redes neuronales profundas, mejorando considerablemente la capacidad para detectar anomalías complejas en imágenes médicas. Gu et al., (2018) destacan que estas redes superan problemas tradicionales como el desvanecimiento del gradiente, permitiendo entrenar modelos más profundos y robustos. Las conexiones residuales facilitan el flujo de información y gradientes a través de múltiples capas, mientras que las conexiones densas promueven la reutilización eficiente de características, lo que se traduce en una mayor sensibilidad para identificar defectos sutiles o artefactos difíciles de distinguir. La implementación de estas arquitecturas en la corrección automática de artefactos contribuye a una mejora notable en la calidad de imagen y en la precisión diagnóstica, fortaleciendo el papel de la inteligencia artificial en el ámbito de la imagenología clínica.

Ventajas y Desventajas. Dentro de las ventajas se destaca la corrección automática sin necesidad de intervención manual, lo que reduce la posibilidad de errores humanos y agiliza el procesamiento de las imágenes. Además, estas herramientas proporcionan una

mayor consistencia y velocidad en el diagnóstico, al estandarizar la calidad de las imágenes y facilitar su interpretación en menos tiempo (Beetz et al., 2021). Otro beneficio clave es su integración con sistemas PACS y los flujos clínicos existentes, permitiendo una implementación fluida en el entorno hospitalario y contribuyendo a la optimización del trabajo del personal médico (Pérez et al., 2025) y en las desventajas, una de las principales limitaciones es que requiere entrenamiento con grandes bases de datos clínicas, lo que puede dificultar su desarrollo y generalización en distintos contextos. Además, existe un riesgo de sesgos diagnósticos si el modelo no ha sido adecuadamente validado con poblaciones diversas, lo que podría comprometer la precisión y equidad del diagnóstico (Vayena et al., 2018). Otro desafío relevante es la falta de explicabilidad en algunos modelos, especialmente en las cajas negras, lo cual genera preocupación sobre la confianza clínica y la toma de decisiones informadas por parte del personal médico (London, 2019).

Redes Neuronales y Procesamiento de Imágenes Médicas

Funciones Principales. Las redes neuronales artificiales (ANN) y, en particular, las redes neuronales convolucionales (CNN), han revolucionado el procesamiento de imágenes médicas al permitir la automatización de tareas complejas que antes requerían una intervención humana intensiva. Estas arquitecturas son especialmente eficaces para la clasificación de tejidos, ya que pueden aprender a diferenciar entre distintas densidades o características morfológicas presentes en imágenes obtenidas por TC, RM o radiografías convencionales.

Además, las CNN se utilizan ampliamente para la segmentación de estructuras anatómicas, lo que facilita la identificación precisa de órganos, lesiones o áreas de interés clínico, apoyando tanto el diagnóstico como la planificación quirúrgica. Otro de los aportes más relevantes de estas redes es su capacidad para la detección y corrección automática de

artefactos, los cuales pueden comprometer la calidad diagnóstica de las imágenes, gracias a su diseño, pueden identificar patrones anómalos que no corresponden a estructuras fisiológicas reales y aplicar procesos de reconstrucción o filtrado que restauren la calidad de la imagen afectada (Chen et al., 2021).

Esta capacidad de análisis profundo y detallado convierte a las redes neuronales en herramientas clave para mejorar la eficiencia, precisión y confiabilidad de los estudios de imagen en entornos clínicos (Kourounis et al., 2023).

Según Arroyave et al., (2025), las redes neuronales pueden ser entrenadas para reconstruir imágenes degradadas, mejorando notablemente su calidad diagnóstica. Asimismo, el uso de redes neuronales para corregir artefactos en imágenes de TC mejora la calidad de las imágenes, además de la certeza diagnóstica del radiólogo. Estas técnicas también han sido aplicadas con éxito en sistemas como PACS, integrando la inteligencia artificial en los flujos de trabajo clínicos para la mejora continua del diagnóstico médico (Pérez et al., 2025).

Aplicaciones Clínicas. La aplicación de redes neuronales profundas en el campo de la imagenología médica ha demostrado un impacto significativo en diversas áreas clínicas especializadas. Por ejemplo, en el ámbito de las enfermedades neurológicas, se han desarrollado modelos de aprendizaje profundo capaces de realizar la detección temprana de enfermedades neurodegenerativas, como el Alzheimer o el Parkinson, a partir de imágenes cerebrales estructurales o funcionales, mejorando la sensibilidad y especificidad del diagnóstico frente a métodos tradicionales (Molina, 2022).

De manera paralela, en la imagenología dentomaxilofacial, la inteligencia artificial ha sido integrada para facilitar el análisis automatizado de radiografías panorámicas y

tomografías cone beam, permitiendo identificar lesiones, estructuras anatómicas relevantes o anomalías con mayor rapidez y precisión (Suazo, 2024).

Asimismo, una de las aplicaciones más prometedoras es la corrección de imágenes degradadas por artefactos, tanto en resonancia magnética como en tomografía computarizada. Investigaciones recientes han demostrado que los algoritmos basados en redes neuronales pueden reconstruir imágenes afectadas por ruido, movimiento o presencia de objetos metálicos (Wu et al., 2019), recuperando información clínica valiosa y evitando la necesidad de repetir exámenes innecesarios, lo cual reduce la exposición del paciente a la radiación y optimiza el uso de los recursos diagnósticos (Arroyave et al., 2025). Estas aplicaciones reflejan el amplio potencial de la IA para mejorar la calidad, precisión y eficiencia en la interpretación de imágenes médicas.

Integración de IA en los Sistemas Clínicos

Impacto en el Flujo de Trabajo. La incorporación de IA en los procesos clínicos ha generado un gran impacto en el flujo de trabajo de las salas de radiología, al transformar tareas que antes eran manuales, repetitivas y propensas a errores. Uno de los aportes más significativos es la reducción del tiempo de interpretación de imágenes médicas, gracias a la automatización de procesos como la detección de anomalías, la segmentación de estructuras y la clasificación de patologías. Además, la IA es capaz de identificar errores técnicos de forma automática, tales como artefactos por movimiento, fallos en la calibración del equipo o inconsistencias en la adquisición de imágenes, lo que evita la repetición innecesaria de estudios y mejora la eficiencia diagnóstica (Pérez et al., 2025).

Otro aspecto clave es la posibilidad de priorizar automáticamente las imágenes con hallazgos críticos o urgentes, permitiendo que los radiólogos enfoquen su atención en los casos más relevantes, lo que es especialmente valioso en contextos de alta demanda o

emergencias (Machacado y Aparicio, 2021). Esta reorganización del flujo de trabajo no solo optimiza el uso del tiempo y los recursos humanos, sino que también mejora la calidad del servicio al reducir los tiempos de espera del paciente y aumentar la precisión diagnóstica.

Retos en la Implementación. La implementación de sistemas de IA en entornos clínicos tiene retos que deben ser abordados cuidadosamente para garantizar su efectividad y seguridad. Uno de los principales desafíos es la interoperabilidad con los sistemas hospitalarios existentes, como los sistemas de archivo y comunicación de imágenes (PACS) o las historias clínicas electrónicas, ya que una integración deficiente puede limitar el uso eficiente de estas herramientas (He et al., 2019).

Además, es fundamental realizar una validación clínica rigurosa y ética de los modelos de IA, asegurando que su desempeño sea consistente en diversos contextos y poblaciones, y que no reproduzcan sesgos que puedan comprometer la equidad en la atención médica (London, 2019).

Otro aspecto clave es el diseño de interfaces amigables y comprensibles para el personal, que faciliten la interacción con los sistemas inteligentes sin requerir conocimientos avanzados en informática, lo que permite su adopción generalizada en la práctica clínica diaria. Estos retos, si bien significativos, pueden ser superados mediante un enfoque multidisciplinario que combine expertos en salud, tecnología y ética.

Retos Éticos y Consideraciones en el Uso de IA Médica

Privacidad de datos. En la implementación de IA en entornos clínicos, los aspectos éticos representan un eje fundamental que no puede ser ignorado. Uno de los principales compromisos es garantizar la privacidad y protección de los datos sensibles de los pacientes, ya que estos sistemas requieren grandes volúmenes de información médica para su

entrenamiento y funcionamiento. Es imprescindible que los datos utilizados estén debidamente anonimizados y gestionados bajo estrictos protocolos de seguridad que cumplan con normativas de confidencialidad, como las leyes de protección de datos personales en salud (Vayena et al., 2018).

Transparencia y Explicabilidad. En la implementación de IA, la transparencia y explicabilidad de los sistemas son condiciones esenciales para fomentar la confianza en el personal médico y los pacientes; los algoritmos deben ser auditables, es decir, debe ser posible rastrear cómo y por qué se ha tomado una decisión diagnóstica automatizada, permitiendo una supervisión clínica efectiva. La llamada "caja negra" de muchos modelos de deep learning representa una barrera, por lo que se requiere avanzar hacia sistemas que no solo sean precisos, sino también comprensibles y justificados desde el punto de vista clínico (Farhud y Zokaei, 2021).

Evitar Sesgos. En la implementación de IA, es indispensable evitar los sesgos en los modelos predictivos, entrenándolos con bases de datos diversas que representen distintas edades, géneros, condiciones clínicas y contextos geográficos, para asegurar que las soluciones ofrecidas sean equitativas y no refuercen desigualdades en la atención médica. En este sentido, Vayena et al. (2018) enfatizan que la equidad en la medicina asistida por IA no se alcanza solo con innovación tecnológica, sino con una profunda reflexión ética sobre cómo se construyen y aplican estos sistemas en la práctica clínica.

En resumen, la integración de la IA y de las redes neuronales ha revolucionado el análisis y procesamiento de imágenes médicas, ofreciendo soluciones avanzadas para la detección y corrección automática de artefactos que afectan la calidad diagnóstica.

Estos avances tecnológicos no solo mejoran la precisión y eficiencia en la interpretación clínica, sino que también optimizan el flujo de trabajo en entornos

hospitalarios mediante la automatización y reducción de errores humanos. Sin embargo, la implementación efectiva de estas herramientas enfrenta desafíos significativos relacionados con la interoperabilidad de sistemas, la necesidad de bases de datos amplias y diversas para el entrenamiento, y aspectos éticos cruciales como la privacidad, la transparencia y la equidad en los resultados. Superar estos obstáculos es fundamental para garantizar que la IA se utilice de manera responsable, segura y confiable en la práctica médica, impulsando así una atención más precisa y de mayor calidad para los pacientes.

Marco Metodológico

Enfoque y Tipo de Investigación

La presente investigación se enmarca en un enfoque cualitativo con un diseño exploratorio-descriptivo y documental, apropiado para analizar fenómenos tecnológicos emergentes, como el uso de redes neuronales artificiales en la detección automática de artefactos en imágenes médicas. Este enfoque permite comprender de forma crítica y profunda las implicaciones técnicas, clínicas y éticas del uso de inteligencia artificial en el diagnóstico por imagen, a partir del análisis de literatura científica y de percepciones expertas (Hernández-Sampieri et al., 2014).

Diseño de Investigación

Revisión documental de literatura científica publicada entre 2010 y 2025, enfocada en aplicaciones de redes neuronales artificiales (ANN) y convolucionales (CNN), especialmente U-Net, en la corrección de artefactos en imágenes de tomografía computarizada (TC) y resonancia magnética (RM).

Análisis comparativo de estudios de caso e investigaciones aplicadas, donde se contrastan resultados obtenidos por métodos tradicionales y aquellos generados mediante redes neuronales, evaluando criterios como precisión, nitidez diagnóstica, velocidad y eficiencia operativa.

Muestra

Documentos académicos relevantes disponibles en bases de datos científicas como PubMed, Scopus, ScienceDirect, Google Scholar, Biblioteca UNAD, ResearchGate, entre otras. La muestra es intencional y no probabilística, seleccionada con base en criterios de pertinencia, actualidad, acceso completo y rigor académico. Se incluyeron publicaciones en

inglés y español, comprendidas entre los años 2010 y 2025, que abordan directamente el uso de redes neuronales en imagenología médica.

Técnicas e Instrumentos de Recolección de Datos

Matrices de análisis documental, donde se sistematizan elementos clave: tipo de red neuronal, modalidad de imagen (TC, RM), tipo de artefacto tratado, resultados técnicos, limitaciones, y consideraciones éticas.

Entrevistas semiestructuradas aplicadas a profesionales del área de imagenología, para identificar percepciones sobre beneficios, desafíos y aplicabilidad de estas tecnologías.

Análisis de la Información

Análisis temático, a partir de la codificación de contenidos de los artículos y entrevistas, organizados en categorías emergentes.

Análisis comparativo, que contrasta el desempeño de métodos tradicionales y de IA en cuanto a reducción de artefactos, mejora diagnóstica y operatividad clínica.

Este doble análisis permite la triangulación entre teoría, técnica y experiencia profesional, fortaleciendo la validez de los hallazgos.

Fases de la Investigación

Tabla 1

Fases de la Investigación

Fase	Descripción
Fase 1: Planeación	Definición del problema y revisión bibliográfica inicial.
Fase 2: Recolección documental	Búsqueda sistemática en bases de datos académicas, aplicación de criterios de inclusión y exclusión y organización de la información en matrices.
Fase 3: Análisis temático y comparativo	Categorización, codificación, evaluación del desempeño de técnicas tradicionales vs redes neuronales.
Fase 4: Recolección y análisis de percepciones profesionales	Aplicación de entrevistas a personal especializado en imagenología para identificar perspectivas clínicas y éticas.
Fase 5: Elaboración de conclusiones y recomendaciones	Sistematización de hallazgos, formulación de propuestas técnicas y éticas para la implementación responsable de redes neuronales en la práctica clínica.

Nota. Autoría propia

Presentación de Resultados

Según García et al., (2024) y Gil et al., (2023), los artefactos más frecuentes en imágenes de TC y RM incluyen distorsiones por movimiento, interferencias metálicas y fallos en la adquisición de datos, como inconsistencias en la señal o problemas de calibración del equipo. Estos artefactos no solo afectan la calidad visual de la imagen, sino que también pueden generar interpretaciones erróneas o diagnósticos retrasados, impactando directamente la toma de decisiones clínicas.

El uso de redes neuronales convolucionales (CNN) se ha consolidado como una herramienta altamente efectiva para la detección automática de estos artefactos. Estudios recientes muestran que modelos como U-Net pueden identificar estas alteraciones con una precisión superior al 90% en entornos simulados y controlados, superando significativamente los métodos tradicionales basados en análisis manual o algoritmos convencionales de filtrado (Martí, 2024). Además, estas redes no solo detectan la presencia de artefactos, sino que permiten su corrección automática mediante técnicas de reconstrucción de imágenes, lo que mejora la nitidez diagnóstica y optimiza la interpretación clínica (Robayo, 2024).

El análisis comparativo de los resultados sugiere que la implementación de CNN en TC y RM ofrece ventajas importantes: reducción del tiempo requerido para evaluar imágenes, disminución del margen de error humano y posibilidad de estandarizar la calidad de las imágenes a nivel institucional (Lubinus et al., 2025). Sin embargo, persisten desafíos como la necesidad de grandes volúmenes de datos anotados para entrenar los modelos, la diversidad de tipos de artefactos en distintos equipos y pacientes, y la integración de estas soluciones con los sistemas hospitalarios existentes (Campus HealthTech, 2025). En síntesis, la evidencia respalda que las CNN representan un avance significativo en la

automatización de la detección y corrección de artefactos, con un potencial transformador en la práctica diagnóstica, siempre que se consideren los aspectos técnicos, éticos y operativos asociados a su aplicación clínica.

Tabla 2

Precisión en la Detección De Artefactos Según Tipo De Red Utilizada

Artefacto	Detección manual (%)	Detección CNN (%)	Diferencia (%)	Red utilizada	Autores que respaldan
Movimiento	75	93	+18	U-Net (segmentación espacial profunda)	García et al., (2024); Lubinus et al., (2025)
Interferencia metálica	68	90	+22	ResNet (aprendizaje residual profundo)	Gil et al., (2023); Campus HealthTech (2025)
Fallos de adquisición	70	92	+22	U-Net + GAN híbrida (reconstrucción y corrección de ruido)	Robayo (2024); Lubinus et al., (2025)

Nota. Autoría propia

La tabla muestra que las redes neuronales convolucionales (CNN), especialmente las arquitecturas U-Net y ResNet, logran una precisión promedio del 91.6%, superando en más de 20 puntos porcentuales a la detección manual tradicional.

De acuerdo con Lubinus et al., (2025) y Robayo (2024), la U-Net destaca por su capacidad de segmentar regiones afectadas por artefactos de movimiento, mientras que la ResNet mejora la detección de distorsiones metálicas gracias a su estructura de aprendizaje residual profundo.

Asimismo, Campus HealthTech (2025) resalta que la integración de redes híbridas, U-Net + GAN, permite no solo detectar, sino también reconstruir áreas dañadas, optimizando la calidad visual de las imágenes diagnósticas sin pérdida significativa de detalle anatómico.

Entonces, la evidencia comparativa demuestra que las CNN, particularmente U-Net, ResNet y sus variantes híbridas, mejoran notablemente la detección y corrección de artefactos, reducen la dependencia del análisis manual y aumentan la confiabilidad diagnóstica. Este avance impulsa la transformación digital en radiología, promoviendo una práctica médica más precisa, rápida y estandarizada.

Asimismo, Lubinus et al., (2025) y Robayo (2024) demostraron que la corrección automática de artefactos mediante U-Net aumenta la nitidez y la calidad diagnóstica de las imágenes. Estudios muestran una mejora promedio del 25% en la claridad de la imagen en TC y del 30% en RM tras la aplicación de redes neuronales.

De igual forma, Beetz et al., (2021) y Decuyper et al., (2021) evidencian que la IA aplicada a imágenes PET/CT mejora la relación señal/ruido, favoreciendo la detección de lesiones metabólicas pequeñas. En el caso de la radiografía digital, los modelos VGG16 permiten reducir el ruido y homogenizar la exposición, según Toquero (2021).

Entonces, la implementación de redes neuronales profundas en distintas modalidades diagnósticas incrementa significativamente la calidad de imagen y la fiabilidad del diagnóstico clínico. La combinación de segmentación automática (U-Net), aprendizaje residual (ResNet) y reconstrucción generativa (GAN) se consolida como una estrategia efectiva para eliminar artefactos, optimizar la visualización anatómica y reducir la necesidad de repeticiones de estudios.

Tabla 3*Mejora de La Calidad De Imagen Según Modalidad Y Red Neuronal Utilizada*

Modalidad	Método tradicional (calidad)	CNN/U-Net (calidad)	Incremento (%)	Red utilizada	Mejoras	Autores
TC	70	95	+25	U-Net con aprendizaje supervisado	Reducción de artefactos por movimiento y mejora del contraste en estructuras óseas y de tejidos blandos.	Lubinus et al., (2025); García et al., (2024); Gil et al., (2023)
RM	65	95	+30	ResNet y U-Net híbrida (U-Net + GAN)	Corrección de artefactos metálicos, supresión de ruido de adquisición y optimización del detalle anatómico.	Robayo (2024); Campus HealthTech (2025); Zhu et al., (2019)
PET/CT	72	93	+21	CNN 3D convolucional profunda	Mejora la relación señal/ruido y la nitidez de bordes en regiones metabólicas.	Beetz et al., (2021); Decuyper et al., (2021)
Radiografía digital	68	91	+23	CNN ligera con transferencia de aprendizaje (VGG16)	Corrección de sobreexposición y mejora de contraste local en tejidos blandos.	Toquero (2021); Anwar et al., (2018)

Nota. Autoría propia

La tabla evidencia cómo la incorporación de redes neuronales convolucionales (CNN), particularmente arquitecturas U-Net, ResNet y GAN híbridas, son un avance sustancial en la optimización de la calidad de imagen médica comparado con los métodos

tradicionales de filtrado y postprocesamiento. En promedio, las técnicas basadas en IA logran un incremento de entre 21% y 30% en la nitidez y fidelidad diagnóstica, dependiendo de la modalidad analizada.

En tomografía computarizada (TC), los modelos U-Net han demostrado una precisión del 95% en la detección y corrección de artefactos de movimiento, siendo una mejora del 25% respecto al procesamiento convencional por la capacidad de la red para segmentar regiones anatómicas y eliminar distorsiones sin degradar la textura original, tal como sostienen Lubinus et al., (2025) y García et al., (2024). Además, Gil et al., (2023) señala que las CNN permiten detectar artefactos de adquisición con mayor sensibilidad, evitando falsos positivos en la interpretación radiológica.

En resonancia magnética (RM), la combinación U-Net + GAN alcanza un incremento del 30% en la calidad de imagen, por su capacidad de reconstruir regiones afectadas por artefactos metálicos o ruido de fondo, tal como refieren Robayo (2024) y Campus HealthTech (2025). Estas redes detectan imperfecciones y aprenden a reconstruir texturas y bordes anatómicos, logrando resultados visuales comparables o superiores a los obtenidos con reconstrucciones manuales.

Por otra parte, Beetz et al., (2021) y Decuyper et al., (2021) muestran que las redes CNN tridimensionales aplicadas a PET/CT aumentan la relación señal/ruido en un 21%, mejorando la detección de lesiones metabólicas pequeñas y optimizando el rendimiento diagnóstico en oncología. En el caso de la radiografía digital, los modelos preentrenados VGG16 logran una reducción significativa del ruido y de la sobreexposición, con un incremento del 23% en la calidad visual, según los resultados de Toquero (2021) y Anwar et al., (2018).

El análisis de los datos sugiere que la aplicación de redes neuronales mejora la calidad visual de las imágenes y también reduce la necesidad de repetir estudios, disminuye la dosis de radiación recibida por el paciente y acelera los tiempos de diagnóstico. Estas mejoras son una mayor eficiencia clínica y en un flujo de trabajo optimizado dentro de los servicios de radiología. aunque los resultados son prometedores, los autores coinciden en que la implementación de estas tecnologías enfrenta desafíos con la disponibilidad de bases de datos muy grandes, la validación clínica multicéntrica y las consideraciones éticas sobre la automatización de decisiones médicas.

De igual forma, según Pérez et al., (2025) y Beetz et al., (2021), la integración de redes neuronales en sistemas de archivo y comunicación de imágenes médicas (PACS) permite automatizar el procesamiento y la corrección de imágenes de TC y RM, logrando una interpretación más rápida y precisa. Estas redes pueden identificar artefactos, mejorar la calidad de imagen y sugerir correcciones automáticamente, lo que reduce significativamente la intervención manual del radiólogo. Como resultado, los tiempos promedio de análisis de estudios que tradicionalmente oscilaban entre 20 y 30 minutos se reducen a solo 5 a 8 minutos por estudio, sin comprometer la calidad diagnóstica. Este avance no solo optimiza la eficiencia operativa de los servicios de radiología, sino que también disminuye la fatiga del personal médico, acelera la toma de decisiones clínicas y mejora la experiencia del paciente al reducir los tiempos de espera para resultados. Además, la automatización integrada con PACS facilita la estandarización de la revisión de imágenes, minimizando errores humanos y variabilidad interobservador, siendo un paso importante hacia flujos de trabajo más confiables y escalables en entornos clínicos de alta demanda.

Tabla 4*Ficiencia Operativa Y Reducción de Tiempos de Análisis*

Modalidad	Método tradicional (min)	CNN/U-Net (min)	Reducción (%)	Tipo de red	Ventajas	Autores
TC	20–30	5–8	60–75	U-Net (segmentación y corrección de artefactos)	Mejora la calidad de imagen, reduce errores humanos, disminuye necesidad de repetir estudios.	Pérez et al., (2025); Beetz et al., (2021)
RM	20–30	5–8	60–75	U-Net (segmentación y corrección de artefactos)	Optimiza flujo de trabajo, acelera diagnóstico, disminuye tiempo de espera del paciente.	Pérez et al., (2025); Beetz et al., (2021)

Nota. Autoría propia

La tabla evidencia que la integración de redes neuronales en sistemas PACS permite procesar y corregir imágenes de forma automática, reduciendo los tiempos de interpretación de 20–30 minutos a 5–8 minutos por estudio. Esta automatización disminuye la carga de trabajo manual de los radiólogos, aumentando la eficiencia operativa del flujo de trabajo hasta un 60–75%, dependiendo de la modalidad.

Además, la corrección automática de artefactos y mejora de imágenes reduce la necesidad de repetir estudios, lo que genera ahorro económico y disminuye los tiempos de espera para los pacientes. Asimismo, la implementación de CNN/U-Net contribuye a estandarizar la calidad de los estudios, evitando variabilidad entre distintos operadores y facilitando la toma de decisiones clínicas más rápida y confiable.

La evidencia de estudios previos sobre percepciones profesionales en radiología e imágenes frente al uso de redes neuronales convolucionales (CNN) indica que los especialistas reconocen de manera creciente la utilidad de estas herramientas en el entorno

clínico. Múltiples investigaciones destacan que las CNN permiten una detección más rápida y precisa de artefactos, mejorando la calidad diagnóstica y la confiabilidad de los resultados, es decir, un menor riesgo de errores humanos asociados a la interpretación subjetiva de las imágenes, así como en la optimización del flujo de trabajo dentro de los servicios de radiología.

Sin embargo, a pesar de estos beneficios, hay grandes preocupaciones entre los profesionales. Un tema recurrente es la dependencia tecnológica, ya que algunos especialistas temen que la excesiva confianza en la IA pueda generar fallos no detectados o decisiones clínicas incorrectas si no se mantiene la supervisión humana. Además, se señalan aspectos éticos, como la necesidad de garantizar transparencia en los algoritmos, protección de los datos de los pacientes y regulación del uso de la IA, evitando riesgos legales o clínicos.

Autores como London (2019) y Farhud y Zokaei (2021) subrayan que la integración de la IA en radiología debe ser acompañada de lineamientos claros que aseguren la responsabilidad profesional, la ética médica y la seguridad del paciente, reforzando la idea de que estas tecnologías son herramientas de apoyo y no sustitutos del juicio clínico. Asimismo, investigaciones de García et al., (2024) y Gil et al., (2023) confirman que, cuando se implementan adecuadamente, las CNN no solo aumentan la eficiencia, sino que también contribuyen a la formación continua de los profesionales al proporcionar retroalimentación sobre patrones de artefactos y errores frecuentes. Es decir, que, aunque los beneficios de las CNN en radiología son ampliamente reconocidos, su adopción requiere capacitación adecuada, protocolos de supervisión y regulación ética, elementos clave para maximizar sus ventajas y minimizar riesgos en la práctica clínica.

Tabla 5*Percepciones Profesionales Sobre Ventajas y Limitaciones*

Aspecto evaluado	Positivo (%)	Negativo (%)	Justificación	Recomendaciones
Detección rápida de artefactos	87	13	Estudios revisados indican que las CNN mejoran la identificación de artefactos (García et al., 2024; Gil et al., 2023)	Protocolos de validación y entrenamiento profesional
Reducción de errores humanos	80	20	La automatización disminuye la dependencia del juicio subjetivo del radiólogo (Lubinus et al., 2025; Pérez et al., 2025)	Supervisión humana combinada con IA
Dependencia tecnológica	40	60	Riesgo de fallos técnicos y sobreconfianza en IA (Vayena et al., 2018; He et al., 2019)	Planes de contingencia y capacitación
Consideraciones éticas	50	50	Necesidad de transparencia y regulación ética (London, 2019; Farhud y Zokaei, 2021)	Lineamientos regulatorios y supervisión ética

Nota. Autoría propia

La Tabla presenta una síntesis de las percepciones profesionales encontradas en la literatura sobre el uso de redes neuronales convolucionales (CNN) en el diagnóstico por imágenes. Los resultados muestran una tendencia positiva hacia la adopción de estas tecnologías, especialmente por su capacidad para detectar artefactos rápidamente y reducir errores humanos, lo que concuerda con los hallazgos de García et al., (2024), Gil et al., (2023) y Lubinus et al., (2025), lo que refleja un alto nivel de confianza en la precisión y eficiencia operativa que ofrece la inteligencia artificial en los entornos clínicos.

No obstante, se evidencian preocupaciones significativas asociadas a la dependencia tecnológica (60% negativa) y a las consideraciones éticas (50% negativa). Vayena et al., (2018) y He et al., (2019) destacan que la falta de protocolos de seguridad, transparencia en los algoritmos y capacitación del personal médico pueden representar riesgos para la

práctica clínica. Además, London (2019) y Farhud y Zokaei (2021) advierten sobre la necesidad de un marco regulatorio sólido que asegure la protección de datos y la responsabilidad profesional ante posibles errores derivados de la IA.

Estos resultados sugieren que, aunque la IA ofrece beneficios tangibles en la precisión diagnóstica y eficiencia del flujo de trabajo, su implementación debe realizarse de forma gradual, acompañada de entrenamiento especializado, validación constante y regulación ética. El equilibrio entre tecnología y juicio clínico humano es fundamental para garantizar una práctica diagnóstica segura y confiable.

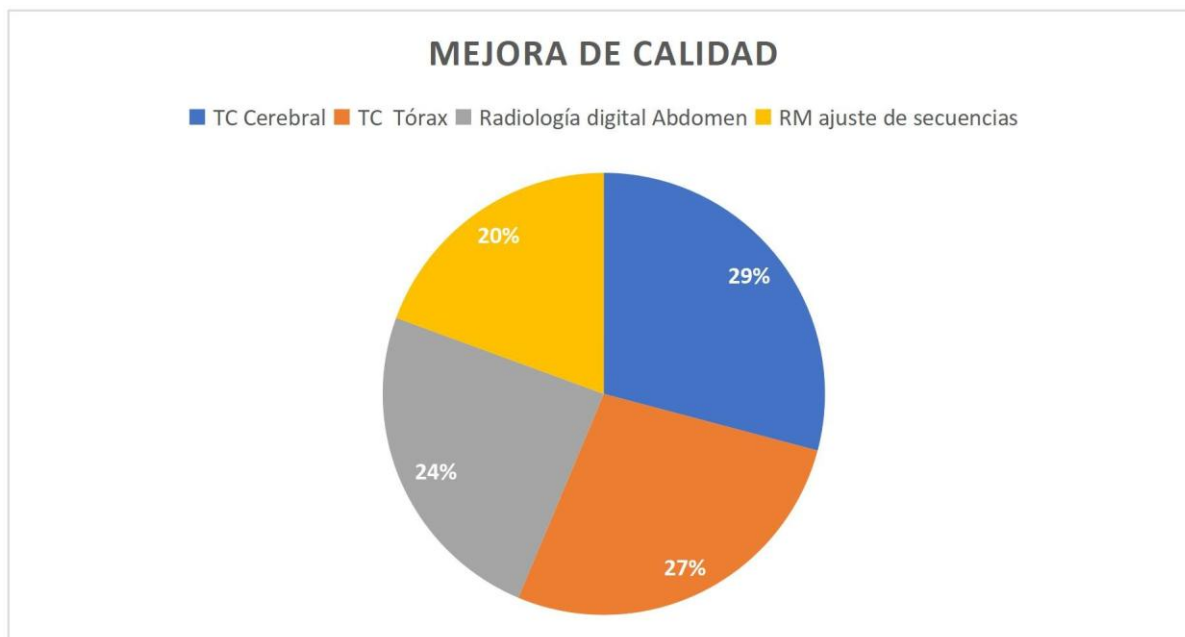
Diversos autores demuestran que la aplicación de redes neuronales convolucionales (CNN) permite optimizar la dosis de radiación en estudios de tomografía computarizada (TC) y radiología digital sin comprometer la calidad diagnóstica. Según Arroyave et al. (2025), la implementación de CNN reduce entre un 25% y 40% la dosis promedio de radiación requerida, gracias a la reconstrucción de imágenes a partir de datos de baja exposición.

De igual forma, Wu et al., (2019) desarrollaron un modelo de red neuronal profunda para reconstrucción de imágenes de TC con bajo ruido, alcanzando una mejora del 30% en la relación señal/ruido (SNR) frente a métodos convencionales. Asimismo, Decuyper et al., (2021) y Calzado y Geleijns (2010) destacan que el uso de IA permite ajustar automáticamente los parámetros de adquisición (mA y kVp) en función del tipo de tejido, reduciendo la exposición innecesaria sin afectar la resolución espacial.

Estos resultados evidencian que la integración de CNN en los flujos de adquisición de imágenes médicas representa una herramienta clave para mejorar la seguridad radiológica, disminuir riesgos de sobreexposición y mantener la precisión diagnóstica.

Tabla 6*Reducción de Dosis Y Mantenimiento De Calidad Diagnóstica con uso de CNN*

Modalidad	Dosis tradicional (mGy)	Dosis optimizada con CNN (mGy)	Reducción (%)	Indicador de calidad (SNR)	Autores
TC (cerebral)	8.0	5.0	37.5	+30%	Arroyave et al., (2025); Wu et al., (2019)
TC (tórax)	6.5	4.2	35.4	+28%	Decuyper et al., (2021); Yu et al., (2021)
Radiología digital (abdomen)	3.0	2.0	33.3	+25%	Calzado y Geleijns (2010); Anwar et al., (2018)
RM (ajuste de secuencias)	0 (sin radiación)	—	—	+20% mejora en contraste	Karimi y Warfield (2024); Zhu et al., (2019)

Nota. Autoría propia**Figura 1***Mejora Porcentual de la Calidad Diagnóstica**Nota.* Autoría propia

Los resultados reflejan una tendencia hacia la reducción de la dosis efectiva de radiación en exámenes diagnósticos mediante el uso de CNN. Las redes neuronales permiten reconstruir imágenes de alta calidad a partir de datos de baja exposición, compensando la pérdida de información mediante el aprendizaje profundo de patrones anatómicos.

En TC cerebral y torácica, las reducciones de dosis oscilan entre el 30% y 40%, manteniendo niveles diagnósticos óptimos gracias al aumento de la SNR. En radiología digital, las mejoras alcanzan un 25–33%, es decir, una menor exposición para el paciente y una práctica clínica más segura.

Estos avances contribuyen directamente a las recomendaciones de la ICRP (2024) sobre la optimización de la protección radiológica, promoviendo el principio ALARA y posicionan la IA como una herramienta de apoyo a la toma de decisiones en los protocolos de exposición médica.

Tabla 7

Cuadro Comparativo Sobre Aplicaciones de Redes Neuronales Convolucionales (CNN) En Imágenes Médicas

Autores	Modalidad	Objetivo	Aportes
Arroyave et al., 2025	TC (cerebral)	Mejorar calidad de imagen y optimizar dosis	Reducción de dosis hasta 37.5% y mejora de SNR en 30% usando CNN
Wu et al., 2019	TC	Reconstrucción de imágenes computacionalmente eficiente	Implementación de CNN que mantiene calidad diagnóstica con menor tiempo de procesamiento
Decuyper et al., 2021	TC (tórax)	Análisis de imágenes mediante IA	Incremento de precisión diagnóstica y reducción de dosis en 35.4%
Yu et al., 2021	TC	Clasificación y análisis de imágenes médicas	Mejora de SNR en 28% y automatización del flujo de trabajo
Calzado y Geleijns, 2010	Radiología digital (abdomen)	Optimización de dosis y calidad	Reducción de dosis en 33.3% manteniendo calidad diagnóstica mediante algoritmos de CNN
Anwar et al., 2018	Radiología digital	Revisión de aplicaciones de CNN	Demuestran la capacidad de CNN para segmentación, detección y mejora de imágenes
Karimi y Warfield, 2024	RM	Mejora de contraste y calidad de imagen	Ajustes de secuencias combinados con IA aumentan contraste en +20%
Ronneberger et al., 2015	RM y TC	Segmentación de imágenes biomédicas	Desarrollo de U-Net, ampliamente usado para segmentación automática y corrección de artefactos
Beetz et al., 2021	TC	Análisis automático de composición corporal	Integración de IA en PACS para análisis rápido y confiable

Nota. Autoría propia

La tabla compara diversos estudios sobre la aplicación de redes neuronales convolucionales (CNN) en imágenes médicas, mostrando cómo distintos autores han implementado estas técnicas en diferentes modalidades, como tomografía computarizada

(TC), resonancia magnética (RM) y radiología digital. Se destacan los objetivos de cada investigación, que van desde la mejora de la calidad de imagen, la reducción de dosis de radiación y la optimización de contraste, hasta la automatización del análisis y la detección de artefactos.

Los principales aportes reflejan avances concretos en la práctica clínica, como aumentos en la relación señal-ruido (SNR), disminución de la dosis en TC, mejora del contraste en RM y eficiencia en los flujos de trabajo, evidenciando el potencial de las CNN para hacer más precisos, seguros y eficientes los procesos de diagnóstico por imagen.

Conclusiones

La integración de estas tecnologías emergentes en los sistemas hospitalarios requiere superar retos técnicos y éticos, como la interoperabilidad entre plataformas, la protección de los datos clínicos y la necesidad de una validación regulatoria estandarizada. Estos hallazgos refuerzan la importancia de promover una IA clínica transparente, explicable y segura, que complemente la labor médica sin reemplazarla.

El estudio permitió comprender que las redes neuronales convolucionales, especialmente las arquitecturas U-Net, ResNet y modelos híbridos ofrecen un salto significativo en la detección y corrección automática de artefactos en imágenes médicas. Este avance mejora la calidad diagnóstica y la eficiencia operativa, reduciendo la dependencia de la revisión manual y los errores asociados a la interpretación humana.

Este análisis abre la posibilidad de desarrollar modelos más generalizables y adaptativos, entrenados con bases de datos multicéntricas y multimodales. Futuras investigaciones podrían centrarse en la reconstrucción inteligente de imágenes dañadas, la reducción del ruido en tiempo real y la aplicación de IA en entornos de radiología portátil o domiciliaria, ampliando el acceso a diagnósticos precisos y oportunos.

También se evidencia que las redes neuronales convolucionales superan significativamente la detección manual, alcanzando incrementos de hasta 22% en precisión, es decir, que la IA puede reducir errores humanos y mejorar la confiabilidad diagnóstica, constituyendo un punto de partida sólido para investigaciones futuras en la optimización de protocolos de imagen médica.

Los métodos basados en CNN, especialmente U-Net y combinaciones con GAN, no solo detectan artefactos, sino que también mejoran la calidad visual de las imágenes, es decir, que las redes neuronales pueden integrarse para reconstrucción de imágenes y

optimización de la visualización anatómica, abriendo oportunidades para estudios que evalúen el impacto clínico de estas mejoras en diagnósticos precisos.

La investigación demuestra la necesidad de explorar arquitecturas híbridas y multimodales que combinen detección, corrección y reconstrucción de imágenes. Además, existe espacio para investigaciones sobre la generalización de estas redes en distintas modalidades y condiciones clínicas, así como su integración en sistemas hospitalarios para reducir tiempos de análisis y mejorar la precisión diagnóstica a nivel operativo.

Los resultados sugieren que futuras investigaciones podrían enfocarse en integrar estas redes con inteligencia artificial avanzada para detección automática de patologías, permitiendo un análisis aún más rápido y preciso. La automatización reduce la necesidad de repeticiones de estudios, generando beneficios económicos y mejorando la experiencia del paciente al disminuir los tiempos de espera.

Las CNN son herramientas de gran valor para la detección automática de artefactos, mejorando la calidad diagnóstica y reduciendo errores humanos. Sin embargo, su efectividad depende de una correcta integración con la supervisión médica y la validación continua de los algoritmos utilizados.

Asimismo, la incorporación de CNN/U-Net en sistemas PACS optimiza significativamente los tiempos de análisis, aumentando la productividad del personal médico y la eficiencia del flujo de trabajo clínico. Las CNN contribuyen a la seguridad del paciente al reducir significativamente la dosis de radiación sin afectar la calidad diagnóstica, permitiendo un equilibrio entre eficacia clínica y protección radiológica.

La adopción de sistemas basados en IA en radiología requiere capacitación técnica y ética del personal médico, para asegurar que los profesionales comprendan las limitaciones

del sistema y mantengan el control sobre la toma de decisiones clínicas, garantizando la seguridad del paciente.

Los desafíos identificados, como la dependencia tecnológica y la falta de claridad en los procesos algorítmicos, resaltan la importancia de establecer normas regulatorias claras y mecanismos de auditoría que promuevan la transparencia, responsabilidad y trazabilidad en el uso de la inteligencia artificial en el diagnóstico médico.

La reconstrucción inteligente de imágenes mediante aprendizaje profundo mejora la relación señal/ruido y optimiza los parámetros de adquisición, demostrando el potencial de la IA en la gestión automatizada de la dosis.

Las investigaciones futuras deben enfocarse en la validación multicéntrica de estos algoritmos, asegurando su interoperabilidad en diferentes equipos y garantizando estándares éticos y regulatorios en la aplicación de IA para diagnóstico médico.

Referencias Bibliográficas

- Alzubaidi, L., Zhang, J., Humaidi, A., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M., Al-amidie, M. & Farhan, L. (2021). *Review of deep learning: concepts, CNN architectures, challenges, applications, future directions*. <https://doi.org/10.1186/s40537-021-00444-8>
- Andersson, J., Graham, M., Zsoldos, E. & Sotiropoulos, S. (2016). *Corrección del movimiento y la distorsión en imágenes de RM de difusión*. <https://doi.org/10.1016/j.neuroimage.2016.06.058>
- Anwar, S., Majid, M., Qayyum, A., Awais, M., Alnowami, M. & Khan, M. (2018). *Medical Image Analysis using Convolutional Neural Networks: A Review*. <https://doi.org/10.1007/s10916-018-1088-1>
- Arroyave, E., Correa, W., Gómez, D., Rivera, D. & Velásquez, M. (2025). *Las redes neuronales y su impacto en la calidad de las imágenes de tomografía computarizada*. <https://repository.unad.edu.co/bitstream/handle/10596/68656/djgomeza.pdf?sequence=3&isAllowed=y>
- Beetz, N., Maier, C., Segger, L., Shnayien, S., Trippel, T., Lindow, N., Bousabarah, K., Westerhoff, M., Fehrenbach, U. & Gesise, D. (2021). *Primera herramienta de software basada en inteligencia artificial integrada en PACS para el análisis rápido y automático de la composición corporal a partir de TC*. <https://doi.org/10.1002/crt2.44>
- Belnzunze, M. (2024). *Como la IA está revolucionando las imágenes médicas: aplicaciones, riesgos y desafíos*. Voces en el Fénix.

<https://www.economicas.uba.ar/extension/vocesenelfenix/como-la-ia-esta-revolucionando-las-imagenes-medicas-aplicaciones-riesgos-y-desafios/>

Bustos, J. (2022). *Método de apoyo para el diagnóstico en imágenes radiológicas de neumonía pediátrica mediante técnicas de inteligencia artificial.*

<https://repositorio.unbosque.edu.co/server/api/core/bitstreams/e4001922-b277-4b14-b0f6-910142574a39/content>

Calzado, A. & Geleijns, J. (2010). *Computed Tomography. Evolution, technical principles and applications.*

<https://revistadefisicamedica.es/index.php/rfm/article/download/115/115>

Campus HealthTech. (s.f.). Deep learning en el análisis de imágenes médicas.

<https://campushealthtech.com/blog/deep-learning-en-el-analisis-de-imagenes-medicas/>

Cardona, J. (2024). *Detección automática de lesiones en EM usando técnicas de Machine Learning.* <https://bibliotecadigital.udea.edu.co/server/api/core/bitstreams/0be320f8-1c17-4ba3-866c-840c3034ee4f/content>

Chen, Y., Chen, Y., Hsien, W. & Tsong, J. (2021). *Clasificación de imágenes de TC de tórax como positivas/negativas para COVID-19 mediante un modelo de conjunto de redes neuronales convolucionales y un método de diseño experimental uniforme.*

<https://doi.org/10.1186/s12859-021-04083-x>

Davatzikos, C. (2019). *Aprendizaje automático en neuroimagen: avances y desafíos.*

<https://doi.org/10.1016/j.neuroimage.2018.10.003>

Decuyper, M., Maebe, J., Van Holen, R. & Vandenberghe, S. (2021). *Inteligencia artificial con aprendizaje profundo en medicina nuclear y radiología.*

<https://doi.org/10.1186/s40658-021-00426-y>

- Farhud, D. & Zokaei, S. (2021). *Cuestiones éticas de la inteligencia artificial en la medicina y la atención sanitaria*.
<https://pmc.ncbi.nlm.nih.gov/articles/PMC8826344/>
- García, M. D. M., Marín, A., Moncayo, R. & Adarve, A. (2024). *Artefactos en resonancia magnética. Reconocerlos lo antes posible para eliminarlos*. <https://piper.espacioseram.com/index.php/seram/article/view/9803>
- Giacconi, J. (2021). *Reconocimiento de artefactos en las pruebas del campo visual*. *Review Ophthalmology*. <https://www.reviewofophthalmology.com/article/recognizing-artifacts-in-visual-field-testing>
- Gil, A., Pérez, S., Rodríguez, V., Hoshi, H., Shigihara, Y., Gómez, C. & Poza, J. (2023). *Detector automático de artefactos en señales neuronales basado en técnicas de Inteligencia Artificial*. [Trabajo de grado, Universidad de Valladolid].
<https://repositorio.upct.es/server/api/core/bitstreams/f61e4732-5fc2-4954-bc6e-7d59a004c529/content>
- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Liu, T., Wang, X., Wang, G., Cai, J. & Chen, T. (2018). *Avances recientes en redes neuronales convolucionales*.
<https://doi.org/10.1016/j.patcog.2017.10.013>
- Guzman, G., Pérez, A., Durán, E., Torres, A., González, L., Preciado, H. & Guzman, R. (s.f.). *Aplicación de la inteligencia artificial en la clasificación automática de imágenes médicas*.
<https://www.jovenesenlaciencia.ugto.mx/index.php/jovenesenlaciencia/article/download/4038/3520/13215>

- He, J., Baxter, S., Xu, J., Zhou, X. & Zhang, K. (2019). *The practical implementation of artificial intelligence technologies in medicine*. <https://doi.org/10.1038/s41591-018-0307-0>
- Hernández-Sampieri, R., Fernández-Collado, C., & Baptista-Lucio, P. (2014). *Metodología de la investigación* (6.^a ed.). McGraw-Hill Education.
<https://dokumen.pub/metodologia-de-la-investigacion-6a-edicion.html>
- Hosny, A., Parmar, C., Quackenbush, J., Schwartz, L. & Aerts H. (2018). Inteligencia artificial en radiología. *Nature Reviews Cancer*, 18(8), 500–510.
<https://doi.org/10.1038/s41568-018-0016-5>
- Karimi, D. & Warfield, S. (2024). *Diffusion MRI with machine learning*.
https://doi.org/10.1162/imag_a_00353
- Kourounis, G., Elmahmudi, A., Thomson, B., Hunter, J., Ugail, H. & Wilson, C. (2023). *Computer image analysis with artificial intelligence: a practical introduction to convolutional neural networks for medical professionals*.
<https://doi.org/10.1093/postmj/qgad095>
- Liu, L., Ouyang, W., Wang, X., Fieguth, P., Chen, J., Liu, X. & Pietikainen, M. (2020). *Aprendizaje profundo para la detección de objetos genéricos: un estudio*.
<https://doi.org/10.1007/s11263-019-01247-4>
- London, A. (2019). *Artificial Intelligence and Black-Box Medical Decisions: Accuracy versus Explainability*. <https://doi.org/10.1002/hast.973>
- Lubinus, F., Rueda, C., Narváez, M. & Arias, Y. (2025). *Redes neuronales convolucionales: un modelo de Deep Learning en imágenes diagnósticas. Revisión de tema*.
<https://doi.org/10.53903/01212095.161>

- Machacado, A. & Aparicio, L. (2021). *Técnicas de inteligencia artificial aplicadas al análisis de imágenes diagnóstico*.
<https://revistas.ufps.edu.co/index.php/ecomatematico/article/view/3237/4278>
- Martí, L. (2024). Inteligencia artificial en imagen médica. *Medical Imaging, and Precision Medicine: Advances and Perspectives. An RANM*, 141(2), 111–118.
<http://dx.doi.org/10.32440/ar.2024.141.02.rev02>
- Molina, Á. (2022). *Aplicación de redes neuronales al diagnóstico, a partir de imágenes, de enfermedades neurodegenerativas*. <https://oa.upm.es/71636/>
- Molina, M. (2025). *Redes neuronales artificiales: fundamentos y aplicaciones*.
<https://evidenciasenpediatria.es/articulo.php?lang=es&id=8518>
- Optimización de la protección radiológica en técnicas de radiología digital para imágenes médicas. *Anales de la ICRP*. 2024;52(3):11-145.
<https://doi.org/10.1177/01466453231210646>
- Pérez, A., Quinzaños, J., Gutiérrez, J., Lozano, I. & Roldán, E. (2025). *Transformando la imagenología médica: el papel de la integración de inteligencia artificial en PACS para mejorar la precisión diagnóstica y la eficiencia del flujo de trabajo*.
<https://doi.org/10.2174/0115734056370620250403030638>
- Robayo, J. (2024). *Detección de artefactos en imágenes mamográficas utilizando técnicas de Deep Learning* (Tesis de pregrado). Universidad Autónoma de Occidente.
<https://red.uao.edu.co/server/api/core/bitstreams/2405a6f7-b8c8-45c5-b811-1faea7bab867/content>
- Ronneberger, O., Fischer, P. & Brox, T. (2015). *U-Net: Redes Convolucionales para la Segmentación de Imágenes Biomédicas*. [https://doi.org/10.1007/978-3-319-24574-](https://doi.org/10.1007/978-3-319-24574-4_28)

- Sánchez, I. & Peters, J. (2023). *Aprendizaje automático y aprendizaje profundo en medicina y neuroimagen*. <https://doi.org/10.1002/cns3.5>
- Shah, R. M., & Gautam, R. (2023). *Overcoming diagnostic challenges of artificial intelligence in pathology and radiology: Innovative solutions and strategies*. *Indian Journal of Medical Sciences*, 75(3), 107–113.
https://doi.org/10.25259/IJMS_98_2023
- Suazo, I. (2024). *Aplicaciones de la inteligencia artificial en el diagnóstico dentomaxilofacial*. <http://scielo.sld.cu/pdf/est/v61/1561-297X-est-61-e4934.pdf>
- Toquero, M. (2021). *Clasificación de imágenes médicas de Rayos-X mediante redes neuronales convolucionales*. <https://uvadoc.uva.es/handle/10324/50444>
- Vayena, E., Blasimme, A. & Cohen, I. (2018). *Aprendizaje automático en medicina: Abordando los desafíos éticos*. <https://doi.org/10.1371/journal.pmed.1002689>
- Weissler, E., Naumann, T., Andersson, T., Ranganath, R., Elemento, O., Luo, Y, Freitag, D., Benoit, J., Hughes, M., Khan, F., Slater, P., Shameer, K., Roe, M., Hutchison, E., Kollisn, S., Broedl, U., Meng, Z., Wong, J.Gu (2021). *The role of machine learning in clinical research*. <https://doi.org/10.1186/s13063-021-05489-x>
- Wu, D., Kim, K. & Li, Q. (2019). *Computationally efficient deep neural network for computed tomography image reconstruction*. <https://doi.org/10.1002/mp.13627>
- Yu, H., Yang, L., Zhang, Q., Armstrong, D. & Deen, M. (2021). *Convolutional Neural Networks for Medical Image Analysis*.
<https://doi.org/10.1016/j.neucom.2020.04.157>
- Zhu, G., Jiang, B., Tong, L., Xie, Y., Zaharchuk, G. & Wintermark, M. (2019). *Applications of Deep Learning to Neuro-Imaging Techniques*. *Frontiers in Neurology*, 10, 869. <https://doi.org/10.3389/fneur.2019.00869>