

**Eficacia de las redes neuronales en la mitigación de artefactos para tomografía  
computarizada y resonancia magnética: Una revisión bibliográfica sobre calidad de imagen**

Cristhian David Abril Angarita

Erika Yulieth Caro Sosa

Jorge Luis Rachen Camargo

Kevin Arlex Montez Márquez

Valeria Bonilla Cano

Asesor:

Christian Camilo Rodríguez Castro

Universidad Nacional Abierta y a Distancia - UNAD

Escuela de Ciencias de la Salud - ECISA

Tecnología en Radiología e Imágenes Diagnósticas

2026

## **Agradecimientos**

Queremos expresar nuestro sincero agradecimiento a nuestro grupo por su dedicación, esfuerzo y colaboración incondicional. Todos y cada uno de nosotros hemos aportado nuestras habilidades y conocimientos únicos, lo que ha hecho que nuestro trabajo colectivo se haya enriquecido con un modelo de mejor todos a la vez; el cual nos ha permitido llegar a las metas deseadas ágilmente.

La sinergia que conseguimos crear entre nosotros ha jugado un activo papel en el proceso de generar ideas innovadoras y en ayudar a establecer los caminos que conseguirían resolver los retos propuestos. Así mismo nuestro agradecimiento y reconocimiento hacia nuestra tutora que, con su orientación y apoyo, ha sabido darnos los consejos prácticos que han sido la clave en el trabajado desarrollo del presente proyecto, como los orientadores que sabían resolver nuestras dudas, de tal modo que nuestras respuestas se hacían necesariamente claras y palpables, y que nos alentaban a seguir adelante. Hasta el momento, sin su ayuda y apoyo, no habiéramos profundizado en este importante avance. Gracias, por darnos la oportunidad de poder seguir aprendiendo y creciendo juntos, formando nuestras capacidades y, a la vez, creando un espíritu de equipo muy por encima de este propio proyecto.

## **Dedicatoria**

A nuestras familias, por su incondicional apoyo y amor, las cuales nos han dotado de la fuerza y motivación para dar este paso. Su confianza en nuestras capacidades ha sido la base estable para poder ir superando los retos que nos encontrábamos. La atención y paciencia con la que escuchaban nuestras inquietudes y las horas que nos regalaban para ofrecernos sus sabidurías y consejos, han sido fundamentales en este camino recorrido. Estamos convencidos de que detrás de cada uno de los logros, hay todo un grupo de personas que han confiado en nosotros para avanzar, a pesar de las dificultades que hemos tenido que ir superando. Su comprensiva manera de soportar nuestras ausencias y el sacrificio de tiempo en familia es símbolo del amor incondicional hacia nosotros. La totalidad de lo expuesto, más aún, hacemos desde aquí una dedicación a nuestras familias, quienes son el sustrato de nuestro crecimiento y éxito. Estamos convencidos de que, sin ellos, no estaríamos escribiendo las últimas páginas de este trabajo.

¡Gracias por estar siempre a nuestro lado!

## Resumen

Este trabajo analiza la eficacia de las redes neuronales en la mitigación de artefactos en Tomografía Computarizada (TC) y Resonancia Magnética (RM), tecnologías esenciales cuya fidelidad diagnóstica se ve frecuentemente alterada por distorsiones visuales denominadas artefactos. El marco teórico establece que estas anomalías como el endurecimiento del haz, los efectos metálicos en TC, o el solapamiento y las imágenes fantasmagóricas en RM surgen de interacciones complejas entre el equipo, el paciente y factores técnicos. Tales errores inducen a "falsos positivos" y obligan a la repetición de estudios, lo que contraviene el principio ALARA al aumentar la dosis de radiación y los costos operativos.

La revisión destaca el potencial de la Inteligencia Artificial, específicamente de las Redes Neuronales Convolucionales (CNN) como U-Net y ResNet, para automatizar la detección y corrección de estas distorsiones. A diferencia de los métodos tradicionales dependientes de la pericia humana, estas arquitecturas permiten identificar patrones complejos para diferenciar la anatomía real del ruido técnico, optimizando la relación señal-ruido. El documento aborda además el marco legal y ético, incluyendo normativas colombianas y la protección de datos, subrayando cómo la automatización busca estandarizar la calidad diagnóstica y garantizar la seguridad del paciente en los servicios de imagenología contemporáneos.

**Palabras clave:** Artefactos, Inteligencia artificial, Redes Neuronales Convolucionales, Tomografía Computarizada, Resonancia Magnética.

## Abstract

This study analyzes the effectiveness of neural networks in mitigating artifacts in Computed Tomography (CT) and Magnetic Resonance Imaging (MRI), two essential technologies whose diagnostic fidelity is frequently compromised by visual distortions known as artifacts. The theoretical framework establishes that these anomalies such as beam hardening and metal-induced artifacts in CT, as well as overlap and ghosting effects in MRI arise from complex interactions between the imaging equipment, the patient, and technical factors. Such errors can lead to false positives and require repeated examinations, thereby contravening the ALARA principle by increasing radiation dose and operational costs.

The review highlights the potential of Artificial Intelligence, specifically Convolutional Neural Networks (CNNs) such as U-Net and ResNet, to automate the detection and correction of these distortions. Unlike traditional methods that rely heavily on human expertise, these architectures enable the identification of complex patterns that distinguish true anatomical structures from technical noise, thereby optimizing the signal-to-noise ratio. The paper also addresses the legal and ethical framework, including Colombian regulations and data protection standards, emphasizing how automation seeks to standardize diagnostic quality and ensure patient safety in contemporary medical imaging services.

**Keywords:** Artifacts, Artificial Intelligence, Convolutional Neural Networks, Computed Tomography, Magnetic Resonance Imaging.

## Tabla de Contenido

Introducción .....	11
Planteamiento del Problema.....	13
Justificación.....	16
Objetivos .....	18
Objetivo General .....	18
Objetivos Específicos .....	18
Marco Teórico .....	19
Fundamentos de la Imagenología Médica.....	19
Generalidades de los Artefactos en Imagen.....	19
Artefactos Específicos en Tomografía Computarizada (TC) .....	20
Artefactos Específicos en Resonancia Magnética (RM) .....	20
Métodos de Corrección y Mitigación .....	21
Inteligencia Artificial en el Diagnóstico Radiológico .....	21
Impacto en la Gestión Hospitalaria.....	22
Antecedentes.....	24
Marco Conceptual .....	26
Fidelidad Diagnóstica .....	26
Artefacto (o Artificio).....	26
Relación Señal/Ruido (SNR) .....	26
Vóxel .....	26

Unidades Hounsfield (UH).....	26
Endurecimiento del Haz (Beam Hardening) .....	27
Efecto de Volumen Parcial (EVP).....	27
Aliasing (o Solapamiento).....	27
Ghosting (Imágenes Fantasma) .....	27
Redes Neuronales Artificiales (RNA) .....	27
Redes Neuronales Convolucionales (CNN) .....	28
Aprendizaje Profundo (Deep Learning) .....	28
U-Net .....	28
ResNet .....	28
Principio ALARA.....	28
Mantenimiento Preventivo .....	29
Marco Legal .....	30
Resolución 482 de 2018 .....	30
Resolución 3100 de 2019 (Sistema Único de Habilitación).....	30
Ley 296 de 1996 .....	31
Protección de Datos y Privacidad (Habeas Data) .....	31
Marco Metodológico .....	32
Tipo de Investigación .....	32
Enfoque de la Investigación .....	32
Método de Investigación .....	32
Fuentes de Información .....	32
Técnicas e Instrumentos de Recolección de Información.....	33

	8
Análisis de la Información.....	34
Artefactos en Tomografía Computarizada (TC).....	34
Artefactos en Resonancia Magnética (RM).....	35
Limitaciones Metodológicas.....	35
Resultados .....	36
Artefactos en TC .....	37
Estudios Realizados, Artículos Presentados como Resultados de Investigación, Documentos en la Red, que Soportan esta Investigación .....	42
Conclusiones .....	50
Referencias Bibliográficas.....	52

**Lista de Tablas**

<b>Tabla 1</b> <i>Tipos de Artefactos</i> .....	37
<b>Tabla 2</b> <i>Comparación del Cerebro Humano vs Computador Convencional</i> .....	37
<b>Tabla 3</b> <i>Análisis Comparativo</i> .....	38

## Lista De Figuras

<b>Figura 1</b> <i>Proceso de los Métodos de DL en Diversos Dominios</i> .....	22
<b>Figura 2</b> <i>Procesamiento y Reconstrucción Basados en Redes Neuronales de Datos de Imágenes Biofotónicas</i> .....	23
<b>Figura 3</b> <i>Servidores</i> .....	23

## Introducción

En el ámbito de la medicina moderna, la obtención de estudios de imagen de alta calidad es indispensable para establecer diagnósticos precisos, diferenciar patologías y realizar seguimientos clínicos efectivos (Sartori et al., 2015). Tecnologías como la Tomografía Computarizada (TC) y la Resonancia Magnética (RM) son herramientas fundamentales que permiten visualizar estructuras anatómicas de forma no invasiva (Camargo et al., 2023). Sin embargo, la calidad de estas imágenes se define por su fidelidad con respecto a la estructura anatómica estudiada, la cual se ve frecuentemente alterada por la presencia de artefactos (Subias & Jerez, 2015). Estos se entienden como anomalías o errores visuales que no corresponden a la anatomía real y que surgen de la interacción entre el equipo, el paciente y factores técnicos (Bejarano et al., 2023). El reconocimiento de estos errores es crucial, ya que pueden generar "falsos positivos" o enmascarar patologías críticas, comprometiendo la veracidad del diagnóstico y obligando a la repetición de estudios, lo que contraviene el principio ALARA al aumentar innecesariamente la dosis de radiación y los costos operativos (Cervantes, 2018; Camargo et al., 2023).

A pesar de la existencia de técnicas manuales y protocolos de mantenimiento para reducir estas distorsiones, persiste un área que no ha sido plenamente identificada ni estandarizada: la viabilidad y efectividad clínica de soluciones automatizadas basadas en Inteligencia Artificial (IA) dentro de los flujos de trabajo rutinarios, especialmente en centros con infraestructura limitada (Lozano et al., 2025). Mientras que los métodos tradicionales dependen de la pericia técnica y el ajuste manual, la literatura científica identifica que el error humano y la falta de capacitación siguen siendo causas prevalentes de degradación de la imagen (Lozano et al., 2025). Esto abre una oportunidad disruptiva para la integración de Redes Neuronales Convolucionales

(CNNs), las cuales han demostrado un gran potencial para automatizar procesos de análisis, identificar patrones complejos y suprimir artefactos sin necesidad de supervisión humana constante (Lozano et al., 2025; Gómez et al., 2025).

Esta investigación se define como una revisión integrativa de la literatura científica, de tipo cualitativo, descriptivo y documental analítico. Su propósito es analizar la eficacia de las Redes Neuronales específicamente arquitecturas como U-Net y ResNet en la mitigación de artefactos críticos en TC y RM, evaluando cómo estas herramientas optimizan la precisión diagnóstica (Lozano et al., 2025; Chen et al., 2023). Para realizar este estudio se emplearán herramientas de búsqueda sistemática en bases de datos especializadas como PubMed, ScienceDirect, SciELO y Scopus, utilizando descriptores técnicos y el análisis de contenido para extraer inferencias de datos secundarios. El valor de este trabajo radica en su capacidad para sintetizar evidencia actual sobre cómo la automatización tecnológica puede garantizar diagnósticos veraces y reducir riesgos para el paciente, aportando un marco de referencia útil para la modernización de los servicios de imagenología.

## Planteamiento del Problema

Desde que Wilhelm Conrad Röntgen descubrió los rayos X en 1895, la medicina ha buscado incansablemente la representación fiel de las estructuras internas del cuerpo humano (Velasco Hidalgo, 2015). En sus inicios, la radiología enfrentó desafíos críticos de calidad; por ejemplo, la primera radiografía odontológica, realizada por el Dr. Walkhoff, requirió una exposición de 25 minutos, resultando en una imagen defectuosa para el diagnóstico debido a la baja sensibilidad de los receptores (Velasco Hidalgo, 2015). Con el tiempo, hitos como la introducción de la Tomografía Computarizada (TC) en 1971 por Godfrey Hounsfield y el desarrollo de la Resonancia Magnética (RM) permitieron visualizaciones tridimensionales detalladas, transformando la práctica clínica (Gómez Alvis et al., 2024; Camargo et al., 2023).

La transición de la radiología convencional a la digital permitió mejoras en la eficiencia operativa y el procesamiento de imágenes (González Barrios et al., 2024). Sin embargo, la obtención de estudios de alta calidad sigue siendo un desafío, ya que la fidelidad de la imagen se ve alterada por la presencia de artefactos (Caicedo et al., 2024). Estos se definen como distorsiones o errores visuales que no tienen correlación con la anatomía real y surgen de la interacción compleja entre el equipo, el paciente y factores técnicos (Arena & Morehouse, 1995; Ortiz et al., 2015).

Históricamente, para mitigar estos errores se han empleado métodos como la interpolación lineal (LI), la reducción de artefactos metálicos normalizada (NMAR) y algoritmos de reconstrucción iterativa (Rodríguez-Gallo et al., 2018; Camargo et al., 2023). A pesar de estos avances, los métodos tradicionales dependen frecuentemente de la pericia del tecnólogo y no siempre logran una supresión total sin degradar la nitidez (Lozano et al., 2025).

En la TC, los artefactos representan un factor crítico que compromete la precisión diagnóstica. Los movimientos del paciente respiratorios, cardíacos o voluntarios son la causa

principal de distorsiones que generan dobles contornos o imágenes difuminadas (Camargo et al., 2023). Asimismo, los materiales de alta densidad como las prótesis generan artefactos metálicos en forma de "rayos de sol", mientras que el endurecimiento del haz provoca bandas oscuras que pueden ocultar patologías reales (Ortiz et al., 2015; Camargo et al., 2023).

Por su parte, la RM es altamente sensible a los artefactos de movimiento que producen imágenes fantasmagóricas a los artefactos de cremallera por interferencias de radiofrecuencia y al solapamiento cuando la estructura anatómica excede el campo de visión (Arena & Morehouse, 1995; Ortiz et al., 2015). La aparición de estos errores induce a "falsos positivos" o dudas diagnósticas, obligando a repetir estudios (Caicedo et al., 2024; Cervantes, 2018). Esto no solo eleva los costos institucionales, sino que en TC aumenta innecesariamente la exposición a la radiación ionizante, contraviniendo el principio ALARA (Gómez Alvis et al., 2024; Lozano et al., 2025).

Ante esta problemática, surge la necesidad de integrar soluciones automatizadas. Las Redes Neuronales Convolucionales (CNNs) representan una oportunidad disruptiva, ya que tienen la capacidad de aprender automáticamente patrones jerárquicos complejos para diferenciar la anatomía real del ruido y los artefactos (Shen et al., 2017; Lozano et al., 2025). Arquitecturas como U-Net y ResNet han demostrado eficacias superiores al 90% en la detección y corrección de distorsiones, optimizando la calidad de la imagen sin necesidad de supervisión humana constante (Lozano et al., 2025; Arroyave Correa et al., 2025). Esta tecnología promete estandarizar la calidad diagnóstica y reducir la variabilidad humana en la interpretación de imágenes médicas (Lozano et al., 2025; Caicedo et al., 2024).

Con base en lo anterior, se plantea la siguiente interrogante: ¿Cuál es la eficacia de las Redes Neuronales en la detección y mitigación de artefactos para la Tomografía Computarizada

y la Resonancia Magnética, y de qué manera su aplicación optimiza la calidad de la imagen diagnóstica según la literatura científica actual?

## Justificación

La presente investigación se fundamenta en la necesidad de analizar la efectividad de las redes neuronales para identificar y subsanar distorsiones en la Tomografía Computarizada (TC) y la Resonancia Magnética (RM), partiendo de que la fidelidad de estas imágenes es vital para la toma de decisiones médicas acertadas (Caicedo, 2024). La relevancia de este estudio radica en que los artefactos no son simples fallas técnicas, sino anomalías que falsean la realidad anatómica y pueden inducir a errores interpretativos críticos o encubrir patologías existentes (Sartori et al., 2015; Caicedo, 2024). Aunque los equipos se consideran dispositivos médicos esenciales para la prevención y el diagnóstico, su interacción con el paciente a menudo genera ruidos, sombras o duplicaciones de contornos que degradan el valor diagnóstico (Caicedo, 2024; Camargo et al., 2023). Al integrar herramientas de Inteligencia Artificial, específicamente Redes Neuronales Convolucionales (CNNs), se busca automatizar procesos de detección que tradicionalmente dependen de la pericia humana, la cual es susceptible a la fatiga y a la presión asistencial (Lozano et al., 2025; Arroyave Correa et al., 2025).

Esta investigación aporta beneficios generales al establecer un equilibrio entre la obtención de imágenes de alta nitidez y la seguridad del paciente. Un beneficio primordial es la optimización del principio ALARA, ya que la mitigación automática de artefactos reduce la necesidad de repetir exámenes, evitando así dosis innecesarias de radiación ionizante en TC y reduciendo la incomodidad del paciente en los largos tiempos de adquisición de la RM (Caicedo, 2024; Camargo et al., 2023). Asimismo, la automatización favorece la estandarización de los informes médicos, eliminando la variabilidad en la interpretación y asegurando que las decisiones clínicas se fundamenten en datos de alta fidelidad (Lozano et al., 2025; Arroyave Correa et al., 2025).

Los hallazgos de esta revisión bibliográfica pretenden beneficiar a múltiples actores del sistema de salud. En primer lugar, los pacientes reciben diagnósticos más veraces y oportunos, lo que evita retrasos en sus tratamientos o la realización de procedimientos invasivos innecesarios por "falsos positivos" (Sartori et al., 2015; Caicedo, 2024). Por otro lado, las instituciones de salud logran una mayor eficiencia operativa y económica al disminuir el gasto derivado de la repetición de pruebas y al optimizar el flujo de trabajo en servicios que suelen presentar alta congestión (Lozano et al., 2025). Finalmente, este trabajo ofrece a la comunidad académica y a otros autores un marco referencial actualizado sobre el uso de tecnologías disruptivas, como el aprendizaje profundo, para fortalecer el control de calidad en la imagenología médica contemporánea (Arroyave Correa et al., 2025; Caicedo, 2024).

## **Objetivos**

### **Objetivo General**

Analizar, mediante una revisión bibliográfica de la evidencia científica actual, la eficacia de las redes neuronales en la detección y mitigación de artefactos para la tomografía computarizada y la resonancia magnética, evaluando su impacto en la optimización de la calidad de imagen y la precisión diagnóstica.

### **Objetivos Específicos**

Catalogar los artefactos críticos identificados en la literatura técnica para tomografía computarizada y resonancia magnética que comprometen la fidelidad de la imagen médica.

Describir las arquitecturas de redes neuronales convolucionales reportadas en la literatura científica para el procesamiento, reconstrucción y realce automático de imágenes en TC y RM.

Evaluar el impacto de los modelos de aprendizaje profundo en la mejora de la relación señal/ruido y la reducción de distorsiones, analizando su contribución al cumplimiento del principio ALARA y la disminución de la repetición de estudios.

Identificar los desafíos tecnológicos y operativos que condicionan la implementación efectiva de estas soluciones automatizadas en los servicios de imagenología contemporáneos.

## **Marco Teórico**

### **Fundamentos de la Imagenología Médica**

La obtención de estudios de alta calidad es un requisito indispensable para establecer diagnósticos precisos y realizar seguimientos clínicos efectivos (Sartori et al., 2015). En el caso de la Tomografía Computarizada (TC), el principio básico de funcionamiento se fundamenta en la medida de las intensidades de un haz de rayos X antes y después de atravesar un tejido, proceso regido por la Ley de Beer-Lambert (Arroyave Correa et al., 2025). Esta ley describe matemáticamente cómo se atenúa la intensidad del haz al interactuar con la materia, permitiendo que la energía detectada sea transformada mediante algoritmos de reconstrucción en una matriz de números conocidos como Unidades Hounsfield (UH) (Camargo et al., 2023). Por otro lado, la Resonancia Magnética (RM) se basa en el comportamiento de los espines nucleares de los protones de hidrógeno al ser sometidos a campos magnéticos intensos y pulsos de radiofrecuencia (Sartori et al., 2015). La liberación de energía durante los procesos de relajación T1 y T2 permite generar imágenes con un contraste superior en tejidos blandos sin el uso de radiación ionizante (Caicedo et al., 2024).

La calidad de estas imágenes se define bajo el concepto de fidelidad, lo que representa el grado de concordancia entre la imagen obtenida y la estructura anatómica real del paciente (González et al., 2024). Factores críticos como la resolución espacial, el contraste, la linealidad y el ruido determinan si una imagen posee el valor diagnóstico necesario para evitar interpretaciones erróneas (González et al., 2024; Buades & González, 2013).

### **Generalidades de los Artefactos en Imagen**

Un artefacto o artificio se define como cualquier distorsión, adición o error visual que aparece en la imagen sin tener un correlato en la anatomía real del sujeto estudiado (Caicedo et

al., 2024). Estas anomalías surgen de una discrepancia entre los coeficientes de atenuación o relajación reales del tejido y los números procesados por el equipo, induciendo lo que se conoce como "falsos positivos" (Cervantes, 2018). La literatura técnica clasifica estas distorsiones en tres categorías principales: de origen físico, derivadas de la naturaleza de la energía; técnicas, vinculadas al estado y calibración del equipo; y relacionadas con el paciente, provocadas principalmente por el movimiento (Sartori et al., 2015; Bejarano et al., 2023).

### **Artefactos Específicos en Tomografía Computarizada (TC)**

En la modalidad de TC, los artefactos de origen físico más prominentes son el endurecimiento del haz (beam hardening) y el efecto de volumen parcial (Camargo et al., 2023). El endurecimiento del haz ocurre cuando los fotones de baja energía son absorbidos por estructuras densas, lo que genera bandas oscuras en la imagen reconstruida (Arroyave Correa et al., 2025). Respecto a los fallos técnicos, se destacan los artefactos de anillo, causados por la falta de calibración o daño en los detectores, que se manifiestan como círculos concéntricos en todos los cortes del estudio (Bejarano et al., 2023). Finalmente, los factores vinculados al paciente incluyen las distorsiones por materiales de alta densidad (metales), que producen destellos en forma de estrella, y el movimiento, que degrada la resolución espacial generando dobles contornos o imágenes difuminadas (Sartori et al., 2015; Camargo et al., 2023).

### **Artefactos Específicos en Resonancia Magnética (RM)**

La RM presenta vulnerabilidades particulares, destacando los artefactos físicos de desplazamiento químico (chemical shift) y susceptibilidad magnética (Sartori et al., 2015). El desplazamiento químico resulta de las diferencias en la frecuencia de precesión entre el agua y la grasa, manifestándose como bandas claras y oscuras en sus interfases (Sartori et al., 2015). La susceptibilidad magnética, por su parte, produce distorsiones graves y vacíos de señal ante la

presencia de materiales ferromagnéticos o aire (Caicedo et al., 2024). En cuanto a los artefactos técnicos, las corrientes de Foucault y la falta de homogeneidad del campo magnético pueden degradar la uniformidad de la imagen (Sartori et al., 2015). Los factores del paciente incluyen el solapamiento (aliasing), que ocurre cuando la anatomía fuera del campo de visión (FOV) se proyecta dentro de la imagen, y el movimiento fisiológico, como el flujo del líquido cefalorraquídeo, que puede simular patologías como la siringomielia (Caicedo et al., 2024; Sartori et al., 2015).

### **Métodos de Corrección y Mitigación**

La mitigación de estas distorsiones se ha abordado tradicionalmente mediante técnicas de post-procesamiento y la optimización de parámetros operativos (Camargo et al., 2023).

Algoritmos como la reducción de artefactos metálicos (MAR) y el uso de filtros bilaterales anisotrópicos han sido fundamentales para reducir el ruido sin sacrificar la nitidez de los bordes anatómicos (Camargo et al., 2023). Asimismo, el ajuste de parámetros como el tiempo de eco (TE), el ancho de banda y el correcto posicionamiento del paciente son estrategias vigentes para minimizar el impacto negativo en el diagnóstico (Sartori et al., 2015; Bejarano et al., 2023).

### **Inteligencia Artificial en el Diagnóstico Radiológico**

La integración de la Inteligencia Artificial (IA) representa el avance más significativo para la detección y corrección automática de artefactos (Lozano et al., 2025). Las Redes Neuronales Convolucionales (CNNs), inspiradas en la estructura del cerebro humano, han demostrado una capacidad superior para aprender patrones jerárquicos complejos y diferenciar la anatomía real del ruido técnico (Shen et al., 2017; Arroyave Correa et al., 2025). Arquitecturas específicas como la U-Net han reportado precisiones del 93% en la detección de distorsiones en RM, mientras que modelos como ResNet son altamente efectivos frente a artefactos múltiples y

complejos (Lozano et al., 2025; Chen et al., 2023). El uso de autoencoders no supervisados permite, además, la eliminación de ruido en imágenes PET sin requerir datos previamente etiquetados, optimizando la legibilidad de los estudios (Lozano et al., 2025).

### **Impacto en la Gestión Hospitalaria**

La aplicación de sistemas automatizados basados en redes neuronales impacta directamente en los criterios de calidad y seguridad del paciente (Lozano et al., 2025). Al reducir la aparición de falsos positivos y negativos, se garantiza que las decisiones clínicas se fundamenten en datos de alta fidelidad (Sartori et al., 2015). Desde una perspectiva económica, la mitigación automática de artefactos disminuye la necesidad de repetir exámenes, lo que se traduce en un ahorro de recursos y en la reducción de dosis de radiación innecesaria, cumpliendo con el principio ALARA (González et al., 2024; Lozano et al., 2025). Finalmente, el mantenimiento preventivo de los equipos, apoyado por herramientas de detección automática, prolonga la vida útil de la tecnología y optimiza el flujo de trabajo en los servicios de imagenología (Pérez & Madrid, 2023; Lozano et al., 2025).

### **Figura 1**

*Proceso de los Métodos de DL en Diversos Dominios*

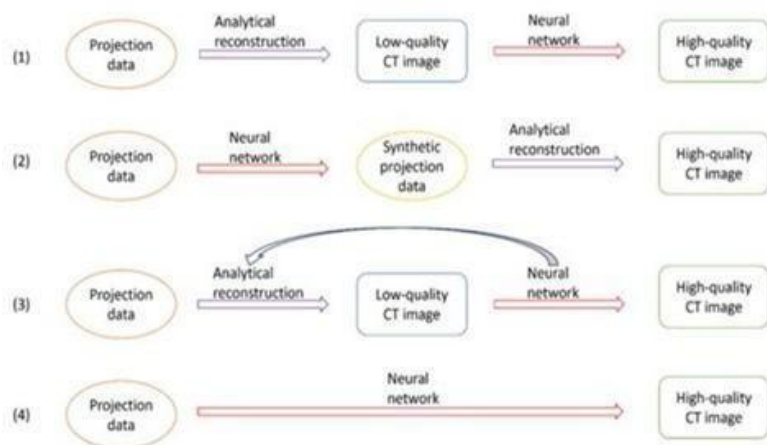


*Nota.* Ciclo de vida de los dominios. Fuente. Otero, L. (2023). Ciclo de vida de un dominio: ¿en qué consiste cada fase? El Blog de Dinahosting.

<https://dinahosting.com/blog/ciclo-de-vida-de-un-dominio/>

**Figura 2**

*Procesamiento y Reconstrucción Basados en Redes Neuronales de Datos de Imágenes Biofotónicas*

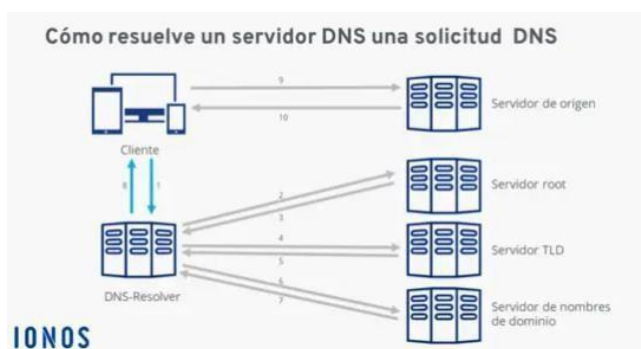


*Nota.* Los diferentes sistemas de procesamiento son herramientas de apoyo al manejo de datos en imágenes médicas. Fuente. Fanous, M. J., Costa, P. C., Işıl, Ç., Huang, L., & Ozcan, A. (2024).

Neural network-based processing and reconstruction of compromised biophotonic image data. *Light Science & Applications*, 13(1), 231.

**Figura 3**

*Servidores*



*Nota.* Los servidores son piezas fundamentales para mantener la infraestructura física de los sistemas.

Fuente. ¿Qué es un servidor DNS? Un vistazo a sus funciones. (2022). IONOS Digital Guide.

<https://www.ionos.es/digitalguide/servidores/know-how/que-es-el-servidor-dns-y-como-funciona/>

## Antecedentes

La literatura muestra una evolución constante en las estrategias para enfrentar la degradación de la imagen diagnóstica. Inicialmente, las investigaciones se centraron en algoritmos matemáticos de suavizado y post-procesamiento. Un estudio relevante realizado por Rodríguez-Gallo et al. (2018) propuso el método ISMAR, basado en el filtro de minimización de gradiente  $L_0$ , para reducir artefactos metálicos en pacientes con prótesis dentales y de cadera.

Sus resultados demostraron que este enfoque superaba a técnicas tradicionales como la interpolación lineal (LI) y la reducción de artefactos normalizada (NMAR), logrando una mejor preservación de las características de los tejidos.

Con la irrupción de la Inteligencia Artificial (IA), el foco de investigación se desplazó hacia la automatización. Yordanova (2024) documentó que las aplicaciones de IA en radiología han crecido significativamente en la última década, abarcando todas las modalidades de imagen y permitiendo una mejora sustancial en la precisión diagnóstica al tiempo que reducen la carga de trabajo del radiólogo. Este avance tecnológico ha permitido que los algoritmos de Deep Learning superen en ciertas tareas la capacidad de detección humana, identificando patrones complejos de ruido y distorsión que tradicionalmente requerían intervención manual.

En el ámbito específico de la Tomografía Computarizada, investigaciones recientes como la de Arroyave Correa et al. (2025) han analizado el impacto de las Redes Neuronales Recurrentes (RNNs) y artificiales en el control de calidad. Estos autores identificaron que el uso de estas redes no solo permite aumentar la resolución de las imágenes, sino que es capaz de reducir la dosis de radiación recibida por el paciente sin comprometer la nitidez del estudio, cumpliendo así con el principio ALARA. Asimismo, Lozano et al. (2025) validaron la viabilidad clínica de las Redes Neuronales Convolucionales (CNNs) para detectar y corregir

automáticamente distorsiones técnicas y por movimiento, reportando eficacias que optimizan la seguridad del paciente y evitan la repetición de exámenes.

Por su parte, en la Resonancia Magnética, la investigación se ha centrado en mitigar la sensibilidad al movimiento y acelerar la adquisición de datos. Shimron y Perlman (2023) destacaron cómo los marcos computacionales de IA están abordando la robustez ante artefactos de movimiento mediante el aprendizaje de imágenes previas, lo que permite una recuperación de la calidad diagnóstica en estudios acelerados. En este mismo sentido, Chen et al. (2023) reportaron que arquitecturas como la U-Net modificada logran una precisión del 93% en la detección y reconstrucción de imágenes afectadas por distorsiones de campo y movimiento involuntario del paciente.

Finalmente, estudios integrales como el de Estienne et al. (2020) han propuesto arquitecturas concurrentes para la segmentación de tumores y el registro de imágenes cerebrales, utilizando redes como la V-Net. Su investigación demostró que el acoplamiento de tareas durante el entrenamiento permite relajar las restricciones de similitud en regiones anormales (como los tumores), mejorando significativamente el rendimiento de la imagen en áreas críticas que suelen presentar altos niveles de error en los registros tradicionales.

## **Marco Conceptual**

### **Fidelidad Diagnóstica**

Se define como el grado de concordancia o exactitud con que la imagen radiográfica obtenida representa la estructura anatómica real del paciente (Zapata Baca, 2019; Subias & Jerez, 2015). Es el parámetro crucial que determina la utilidad de una radiografía para la decisión clínica (Velasco Hidalgo, 2015).

### **Artefacto (o Artificio)**

Cualquier característica visual falsa, distorsión o error en una imagen médica que no tiene un correlato anatómico real y surge de la interacción entre el equipo, el paciente y factores técnicos (Cervantes, 2018; Ortiz et al., 2015). Estos pueden enmascarar patologías o inducir a "falsos positivos" (Arena & Morehouse, 1995).

### **Relación Señal/Ruido (SNR)**

Es la métrica que evalúa la calidad de la señal de interés frente a las variaciones aleatorias indeseables (ruido) que degradan la nitidez de la imagen (Ramírez et al., 2010; González Barrios et al., 2024).

### **Vóxel**

Representa la unidad mínima de volumen tridimensional en la cual se divide la anatomía del paciente durante la adquisición de una imagen digital (Camargo et al., 2023; Arroyave Correa et al., 2025).

### **Unidades Hounsfield (UH)**

Escala numérica utilizada en TC para expresar el coeficiente de atenuación lineal de los tejidos en relación con el agua, permitiendo diferenciar estructuras según su densidad (Camargo et al., 2023; Geleijns, 2010).

**Endurecimiento del Haz (Beam Hardening)**

Fenómeno físico que ocurre cuando el espectro de energía de un haz de rayos X se desplaza hacia energías más altas al atravesar tejidos densos, provocando bandas oscuras en la imagen final (Barrett & Keat, 2004; Arroyave Correa et al., 2025).

**Efecto de Volumen Parcial (EVP)**

Error que se produce cuando estructuras de diferentes densidades ocupan un mismo vóxel, lo que resulta en un valor promedio impreciso que desdibuja los contornos anatómicos (Buzug, 2008; Camargo et al., 2023).

**Aliasing (o Solapamiento)**

Artefacto que sucede cuando el objeto estudiado excede el campo de visión (FOV) seleccionado, provocando que la anatomía periférica se proyecte erróneamente en el borde opuesto de la imagen (Arena & Morehouse, 1995; Caicedo et al., 2024).

**Ghosting (Imágenes Fantasma)**

Réplicas difusas o duplicaciones de las estructuras anatómicas que aparecen en la dirección de codificación de fase debido a movimientos fisiológicos como la respiración o el flujo sanguíneo (Sartori et al., 2015; Caicedo et al., 2024).

**Redes Neuronales Artificiales (RNA)**

Modelos computacionales inspirados en la interconexión de neuronas biológicas, capaces de aprender patrones complejos a partir de datos para realizar tareas de reconocimiento y clasificación (Matich, 2001; Minsky & Papert, 1969).

## **Redes Neuronales Convolucionales (CNN)**

Arquitecturas de aprendizaje profundo especializadas en el procesamiento de datos estructurados como imágenes, que utilizan mecanismos de campos receptivos locales y pesos compartidos para identificar características jerárquicas (Shen et al., 2017; Lozano et al., 2025).

### ***Aprendizaje Profundo (Deep Learning)***

Subdisciplina de la inteligencia artificial que emplea múltiples capas ocultas en redes neuronales para extraer representaciones informativas de alto nivel directamente de los datos brutos (Shen et al., 2017; Arroyave Correa et al., 2025).

### **U-Net**

Arquitectura específica de red neuronal de tipo codificador-decodificador, altamente eficaz en la reconstrucción de imágenes médicas y la corrección de artefactos de movimiento (Lozano et al., 2025; Chen et al., 2023).

### **ResNet**

Modelo de red residual que facilita el entrenamiento de redes muy profundas mediante conexiones de salto, resultando eficaz frente a distorsiones múltiples y complejas (Lozano et al., 2025; Elhanashi et al., 2025).

### **Principio ALARA**

Acrónimo de "*As Low As Reasonably Achievable*", directriz ética y técnica que obliga a mantener la dosis de radiación tan baja como sea razonablemente posible para obtener una imagen de calidad diagnóstica (Velasco Hidalgo, 2015; González Barrios et al., 2024).

**Mantenimiento Preventivo**

Conjunto de acciones periódicas de inspección, limpieza y calibración realizadas a los equipos de rayos X para asegurar su correcto funcionamiento y evitar la degradación de la calidad de imagen (Lozano et al., 2025; Delgado Orozco et al., 2024).

## Marco Legal

En el ámbito internacional, el ejercicio de la radiología se rige por el principio ALARA (As Low As Reasonably Achievable), el cual establece que la exposición a la radiación ionizante debe mantenerse tan baja como sea razonablemente posible, siempre que se obtenga una calidad diagnóstica adecuada (Velasco Hidalgo, 2015; Gómez Alvis et al., 2024). Este principio es fundamental al evaluar la eficacia de las redes neuronales, ya que la optimización automática de imágenes permite reducir la dosis sin sacrificar la fidelidad del estudio (Lozano et al., 2025).

Asimismo, se consideran las directrices del Organismo Internacional de Energía Atómica (OIEA), que fomenta la aplicación de normas de seguridad para proteger la salud humana en el uso de equipos generadores de radiación (Gómez Alvis et al., 2024; Bejarano et al., 2023).

La prestación de servicios de imagenología en Colombia está sujeta a requisitos técnicos y científicos específicos definidos por el Ministerio de Salud y Protección Social

### **Resolución 482 de 2018**

Esta norma reglamenta el uso de equipos generadores de radiación ionizante, estableciendo la obligatoriedad del control de calidad y la prestación de servicios de protección radiológica (Gómez Alvis et al., 2024; Pérez & Madrid, 2023). El cumplimiento de esta resolución asegura que los equipos de TC operen bajo parámetros técnicos que minimicen la aparición de artefactos por fallas del sistema (Delgado Orozco et al., 2024).

### **Resolución 3100 de 2019 (Sistema Único de Habilitación)**

Define los estándares mínimos que deben cumplir las Instituciones Prestadoras de Servicios de Salud (IPS). Esta normativa exige de manera obligatoria el mantenimiento preventivo de los equipos de radiología para garantizar la seguridad del paciente y la vigencia de la licencia de funcionamiento (Delgado Orozco et al., 2024). La falta de este mantenimiento se

vincula directamente con una degradación en la calidad de la imagen y errores diagnósticos (Delgado Orozco et al., 2024; Pérez & Madrid, 2023).

### **Ley 296 de 1996**

Aprueba acuerdos suplementarios sobre el uso seguro de la tecnología nuclear y radiológica en el territorio nacional, reforzando los estándares de seguridad diagnóstica (Gómez Alvis et al., 2024).

### **Protección de Datos y Privacidad (Habeas Data)**

La integración de Redes Neuronales Convolucionales (CNNs) implica el manejo masivo de datos clínicos para su entrenamiento y validación. En este sentido, rige el Artículo 15 de la Constitución Política de Colombia, que consagra el derecho al Habeas Data, permitiendo que los ciudadanos conozcan, actualicen y rectifiquen la información recogida sobre ellos (Lozano et al., 2025). Para cumplir con esta disposición, se exige la implementación de técnicas de anonimización y encriptación de las imágenes médicas, garantizando que la identidad del paciente no sea vulnerada durante los procesos de detección y corrección automática de artefactos (Lozano et al., 2025).

Desde el punto de vista ético y legal, la aplicación de algoritmos de inteligencia artificial no exime al personal médico de su responsabilidad. Los radiólogos deben mantener una supervisión activa para validar los resultados generados por la IA y evitar la dependencia absoluta de los sistemas automáticos (Lozano et al., 2025). Además, se resalta la importancia del consentimiento informado, mediante el cual se comunica al paciente sobre el tipo de examen a realizar y los posibles riesgos o efectos adversos, asegurando una práctica humanizada y transparente (Sartori et al., 2015; Caicedo et al., 2024).

## **Marco Metodológico**

### **Tipo de Investigación**

El presente trabajo se clasifica como una investigación de tipo descriptivo y documental, basada en la consulta, análisis e interpretación de información obtenida de diversas fuentes bibliográficas. A través de este proceso de revisión, se busca analizar la eficacia de las redes neuronales artificiales (RNA) y convolucionales (CNN) en la detección y mitigación de los artefactos críticos que afectan la Tomografía Computarizada (TC) y la Resonancia Magnética (RM), tales como el movimiento, los materiales metálicos y el endurecimiento del haz

### **Enfoque de la Investigación**

Este estudio tiene un enfoque cualitativo. Su objetivo no es medir ni cuantificar variables, sino comprender los fenómenos que intervienen en la formación de artefactos desde una perspectiva técnica y conceptual, se pretende analizar la información existente en la literatura científica y académica para obtener una visión más profunda del tema, construyendo un marco teórico actualizado que sirva de apoyo a la práctica radiológica.

### **Método de Investigación**

Para el desarrollo de la investigación se utilizó el método analítico-descriptivo, ya que este permite examinar de manera ordenada los diferentes tipos de artefactos y las causas que los generan, además, facilita describir de forma clara cómo estos afectan la calidad de las imágenes diagnósticas y qué procedimientos o tecnologías contribuyen a su corrección, con este método fue posible integrar la información revisada y presentarla de manera coherente y comprensible.

### **Fuentes de Información**

Las fuentes consultadas fueron principalmente bibliográficas y digitales, se revisaron artículos científicos disponibles en bases de datos reconocidas como PubMed, Scielo y

ScienceDirect, además de libros especializados en radiología, imagenología y física médica descargados o comprados, también se tuvieron en cuenta documentos académicos y guías técnicas publicadas por sociedades radiológicas internacionales, todas las fuentes fueron seleccionadas por su actualidad, confiabilidad y pertinencia con el tema investigado.

### **Técnicas e Instrumentos de Recolección de Información**

Para la búsqueda de información en el presente estudio, se definieron términos técnicos específicos que captan la idea central de la investigación, empleando descriptores o palabras clave tanto en español como en inglés, entre los que se destacan inteligencia artificial (artificial intelligence), redes neuronales convolucionales (convolutional neural networks), artefactos en imágenes médicas (medical image artifacts), tomografía computarizada (computed tomography), resonancia magnética (magnetic resonance imaging) y aprendizaje profundo (deep learning).

En cuanto a los criterios de inclusión, se seleccionaron estudios centrados específicamente en el uso de arquitecturas de redes neuronales como CNN, U-Net y ResNet para la detección o corrección de artefactos, priorizando investigaciones publicadas en un rango de tiempo comprendido entre los años 2010 y 2025 principalmente, con especial interés en la producción científica de los últimos cinco años para asegurar la vigencia tecnológica. Asimismo, se incluyeron publicaciones en idiomas español e inglés que demostraran un alto rigor metodológico y respaldo institucional o académico, enfocándose en artículos que abordaran el impacto de la inteligencia artificial en la reducción de la dosis de radiación, bajo el cumplimiento del principio ALARA, y en la optimización de la precisión diagnóstica.

Por el contrario, los criterios de exclusión aplicados descartaron estudios que no abordaran la temática de los artefactos diagnósticos o que se enfocaran en áreas de la imagenología sin relación directa con el problema investigado. De igual manera, se omitieron

fuentes sin validación académica verificable o que presentaran opiniones sin sustento empírico o técnico, así como textos que, a pesar de tratar sobre inteligencia artificial, no analizaran su aplicación específica en la mejora de la calidad de las imágenes médicas.

### **Análisis de la Información**

El proceso de análisis se fundamenta en la sistematización, clasificación y comparación de la evidencia científica recolectada, orientándose a determinar la eficacia de las redes neuronales convolucionales (CNNs) frente a los métodos tradicionales de detección y corrección (Arias, 2012; Lozano et al., 2025). Se identifican los artefactos de mayor prevalencia clínica, evaluando cómo la automatización mediante herramientas de Inteligencia Artificial (IA) permite el reconocimiento de patrones jerárquicos complejos para diferenciar la anatomía real de las señales espurias o ruido técnico (Lozano et al., 2025; Shen et al., 2017). El análisis culmina en una síntesis interpretativa que vincula la mitigación automática de distorsiones con la optimización de la fidelidad diagnóstica y el cumplimiento de los estándares de seguridad y atención humanizada del paciente (Sartori et al., 2015; Lozano et al., 2025; Caicedo et al., 2024).

### **Artefactos en Tomografía Computarizada (TC)**

Para la modalidad de TC, el análisis se centra en fenómenos críticos como el movimiento cinético, el efecto de endurecimiento del haz (beam hardening), el volumen parcial y las distorsiones asociadas a materiales de alta densidad como prótesis o clips quirúrgicos (Sartori et al., 2015; Camargo et al., 2023; Muñoz et al., 2023). Se examina la transición desde las estrategias físicas convencionales ajustes de voltajes y filtros y los algoritmos de reconstrucción iterativa, hacia el uso de arquitecturas de aprendizaje profundo (deep learning) (Sartori et al., 2015; Arroyave Correa et al., 2025). Se evalúa específicamente cómo modelos basados en ResNet y YOLOv8 logran mitigar artefactos metálicos y de ruido estructural sin incrementar la

exposición a la radiación ionizante, favoreciendo la adherencia estricta al principio ALARA (As Low As Reasonably Achievable) (Elhanashi et al., 2025; Arroyave Correa et al., 2025).

### **Artefactos en Resonancia Magnética (RM)**

En el ámbito de la RM, el estudio profundiza en los artefactos por susceptibilidad magnética, el solapamiento (aliasing), la falta de homogeneidad del campo B0 y los movimientos fisiológicos involuntarios, tales como la respiración y el latido cardíaco (Sartori et al., 2015; Caicedo et al., 2024). El análisis incluye la valoración de secuencias rápidas y técnicas de sincronización, pero prioriza el estudio de aproximaciones modernas basadas en redes como U-Net (Lozano et al., 2025; Chen et al., 2023). Se analiza la capacidad de estas redes neuronales para realizar reconstrucciones aceleradas que restauran la fidelidad espacial y de contraste, permitiendo una recuperación de la calidad diagnóstica que logra reducciones reportadas de hasta un 35% en la necesidad de repetir estudios por distorsiones de movimiento (Najjar, 2023; Chen et al., 2023; Shimron & Perlman, 2023).

### **Limitaciones Metodológicas**

Se documentaron limitaciones inherentes a la revisión documental: heterogeneidad en los diseños experimentales de los estudios incluidos, variabilidad en los phantoms o muestras utilizadas y falta en ocasiones de validación clínica amplia. Estas limitaciones se tuvieron en cuenta al elaborar recomendaciones y al proponer líneas futuras de investigación que requieran validación prospectiva en entornos clínicos.

## Resultados

En el desarrollo de la presente revisión literaria, centrada en los artefactos que surgen en los estudios de Tomografía Computarizada (TC) y Resonancia Magnética (RM), se ha reconocido que una proporción significativa de las imágenes diagnósticas no alcanza los estándares de calidad requeridos para una adecuada interpretación clínica (Sartori et al., 2015; Arena & Morehouse, 1995). A partir del análisis de diversos estudios, se evidencia que la mayoría de estas limitaciones provienen de artefactos generados durante la fase de adquisición del examen, los cuales resultan de la interacción compleja entre el equipo, el paciente y factores técnicos (Caicedo et al., 2024; Camargo et al., 2023).

Factores comunes como el movimiento involuntario del sujeto, la dinámica respiratoria, fallos menores en la sincronización de los equipos, errores de calibración en los detectores o las limitaciones intrínsecas del hardware alteran significativamente la reconstrucción final de los estudios de TC y RM (Sartori et al., 2015; Bejarano et al., 2023; Camargo et al., 2023). Estas distorsiones repercuten de manera directa en la nitidez y fidelidad de la imagen, lo cual no solo obstaculiza la labor diagnóstica del profesional de la salud, sino que aumenta el riesgo de incurrir en interpretaciones incompletas o imprecisas que pueden simular patologías inexistentes (Arena & Morehouse, 1995; Cervantes, 2018; Sartori et al., 2015).

En la tabla 1 se relacionan algunas causas principales para conseguir una imagen diagnóstica con artefactos o artificios en TC, cabe destacar que cualquiera de los ítems relacionados puede ocurrir en distintos estudios y el principal objetivo que se busca es evitarlos a través del diálogo con el paciente, mantenimiento constante del equipo y el uso de redes neuronales como método complementario al detectar y corregir dichos artefactos que interfieren en una imagen de calidad diagnóstica.

**Tabla 1***Tipos de Artefactos*


---

Artefactos en TC

---

Movimientos del paciente

Presencia de cuerpos extraños/material médico Errores en las medidas de atenuación de los rayos X

Endurecimiento del haz de rayos X cuando estos traspasan al paciente Efecto de volumen parcial Ruido (quantum mottle)

Mal funcionamiento de los detectores como consecuencia de errores de calibración o balanceo, efectos geométricos

Errores de espiral o “de remolino” Factores ambientales

---

*Nota.* Sartori et al., 2015. Revista Argentina De Radiología. Artefactos y artificios frecuentes en TC y RM (p. 198).

**Tabla 2***Comparación del Cerebro Humano vs Computador Convencional*

Características	Cerebro Humano	Computador
Velocidad de proceso	Entre $10^{-3}$ y $10^{-2}$ seg.	Entre $10^{-8}$ y $10^{-9}$ seg.
Estilo de procesamiento	Paralelo	Secuencial (en serie)
Numero de procesadores	Entre 10 <sup>11</sup> y 10 <sup>14</sup>	Pocos
Conexiones Almacenamiento del conocimiento	10.000 por procesador	Pocas
Tolerancia a fallos	Distribuido	En direcciones fijas (posiciones precisas)
Tipo de control del proceso	Amplia	Poca o nula
Consumo de energía para ejecutar una operación/sg	Autoorganizado (democrático) Entre $10^{-3}$ y $10^{-2}$ se 10-16 Julios	Centralizado (dictatorial) 10-6 Julios

*Nota.* Flórez et al., 2008. Redes neuronales artificiales Fundamentos teóricos y aplicaciones prácticas (p. 12). Nebiblo.

Durante la investigación se ha analizado la importancia de las redes neuronales en el ámbito diagnóstico, siendo esta una evolución para el diagnóstico certero, el cual se relaciona en la siguiente figura como evidencia de un resultado positivo utilizando redes neuronales.

Mediante la revisión bibliográfica se analizaron distintos artículos relacionados a redes neuronales para comprender el funcionamiento de ellas y su comportamiento. Según Flórez, (2008). “Las RNAs tratan de emular el comportamiento del cerebro humano, caracterizado por el aprendizaje a través de la experiencia y la extracción de conocimiento genérico a partir de un conjunto de datos”. En este sentido se relaciona la tabla 3.

**Tabla 3***Análisis Comparativo*

Colombia	Países Bajos	Reino Unido	Alemania
Institución: Universidad Nacional Abierta y a Distancia – UNAD. Escuela de Ciencias de la Salud (ECISA).	Institución: Centro TechMed, Universidad de Twente.	Institución: Cancer Research UK – Instituto de Cambridge; University of Cambridge; University College London.	Institución: Centro Médico Universitario de Gotinga y Max Planck Institute for Multidisciplinary Sciences.
Área de investigación: Programa académico, Diplomado en Control de la Calidad en Radiología Digital.	Área de investigación: Imagen Fotoacústica (PAI).	Área de investigación: Física médica, ingeniería biomédica y desarrollo computacional aplicado a imagen médica.	Área de investigación: Investigación multidisciplinaria en ciencias físicas aplicadas a imagen médica.
Artículo científico: Trabajo desarrollado: Artefactos en imágenes radiológicas que afectan la calidad diagnóstica (TC y RM).	Artículo científico: Artefactos en imágenes fotoacústicas: orígenes y mitigaciones (ScienceDirect, Vol. 45, 2025).	Artículo científico: Participación en desarrollo teórico y computacional del estudio fotoacústico.	Artículo científico: Participación en investigación experimental y desarrollo físico- tecnológico.
Naturaleza tecnológica: Tecnologías consolidadas (Tomografía Computarizada y Resonancia Magnética).	Naturaleza tecnológica: Tecnología emergente que combina luz láser y ondas acústicas para generar imágenes híbridas.	Naturaleza tecnológica: Desarrollo de modelos físicos y matemáticos para reconstrucción de imagen fotoacústica.	Naturaleza tecnológica: Innovación en procesos físicos y análisis estructural de limitaciones tecnológicas.

Origen de artefactos: Movimiento del paciente, parámetros de adquisición, interferencias electromagnéticas, limitaciones del hardware y procesos de reconstrucción matemática (Fourier y retroproyección filtrada).	Origen de artefactos: Limitaciones en propagación óptica y medición acústica incompleta.	Origen de artefactos: Suposiciones matemáticas en algoritmos de reconstrucción y modelado computacional.	Origen de artefactos: Atenuación, dispersión y limitaciones físicas inherentes al método fotoacústico.
Clasificación de artefactos: Estandarizada y validada científicamente (beam hardening, artefactos metálicos, susceptibilidad magnética, aliasing, efecto Gibbs, entre otros).	Clasificación de artefactos: basada en limitaciones físicas y errores de adquisición.	Clasificación de artefactos: Enfoque en errores derivados del procesamiento computacional.	Clasificación de artefactos: Enfoque estructural y físico de los artefactos emergentes.
Impacto clínico: Aplicación inmediata en hospitales y clínicas; mejora directa de la calidad diagnóstica y reducción de errores médicos.	Impacto clínico: impacto prospectivo; busca perfeccionar tecnología antes de su implementación clínica masiva.	Impacto clínico: contribución al desarrollo futuro de equipos más precisos y confiables.	Impacto clínico: aporte a la evolución tecnológica de sistemas avanzados de imagen médica.
Estrategias de mitigación: Optimización de	Estrategias de mitigación: desarrollo de algoritmos	Estrategias de mitigación: innovación computacional y mejora	Estrategias de mitigación: investigación en

parámetros técnicos, protocolos clínicos estandarizados, algoritmos de reducción de artefactos (MAR, MARS, SENSE, SWI) y capacitación profesional.	avanzados de reconstrucción y mejoras en sensores acústicos.	de modelos matemáticos.	mejoras físicas y estructurales del sistema de adquisición.
Enfoque general: clínico– aplicado, basado en evidencia consolidada y práctica hospitalaria real.	Enfoque general: experimental y tecnológico, orientado a innovación científica.	Enfoque general: físico- computacional, centrado en modelado matemático avanzado.	Enfoque general: experimental-físico, enfocado en limitaciones estructurales y evolución tecnológica.

*Nota:* El análisis de la tabla evidencia una diferencia significativa en el enfoque y nivel de desarrollo tecnológico entre los países comparados. Fuente. Autoría Propia.

En el caso de Colombia, el estudio se centra en tecnologías consolidadas como la Tomografía Computarizada y la Resonancia Magnética, cuyo marco teórico y clasificación de artefactos ya se encuentran estandarizados y validados científicamente. El enfoque es

principalmente clínico-aplicado, orientado a optimizar la calidad diagnóstica en contextos hospitalarios reales y a reducir errores en la interpretación de imágenes.

Por su parte, los aportes de Países Bajos, Reino Unido y Alemania se enfocan en la investigación de la Imagen Fotoacústica, una tecnología emergente aún en proceso de transición hacia el ámbito clínico. En estos países, el análisis de los artefactos parte de limitaciones físicas y computacionales inherentes al método, lo que implica un enfoque experimental, físico y matemático más profundo. La clasificación de artefactos no está completamente estandarizada, ya que la tecnología continúa evolucionando.

En términos de impacto, mientras que el estudio colombiano tiene una aplicación inmediata

en la práctica clínica, el trabajo europeo presenta un impacto prospectivo, orientado al diseño y perfeccionamiento de futuras generaciones de equipos médicos. En consecuencia, ambos enfoques convergen en el propósito de mejorar la calidad diagnóstica, pero difieren en su nivel de madurez tecnológica, alcance metodológico y proyección científica.

### **Estudios Realizados, Artículos Presentados como Resultados de Investigación, Documentos en la Red, que Soportan esta Investigación**

La literatura revisada evidencia que el aprendizaje automático y, en particular, el aprendizaje profundo ha redefinido el panorama del procesamiento y la reconstrucción de imágenes en tomografía computarizada (TC). No obstante, lejos de constituir una solución universal, estos enfoques presentan fortalezas y limitaciones que deben analizarse de manera crítica y comparativa. Uno de los aspectos más recurrentes en los estudios es la dependencia de grandes volúmenes de datos para garantizar un rendimiento estable y confiable. Zhang et al. (2022) señalan que, en escenarios de TC de baja dosis, la escasez de muestras puede comprometer seriamente la capacidad de generalización de los modelos, generando resultados inconsistentes o incluso inferiores a los métodos analíticos convencionales. Esta observación introduce una tensión clave entre el potencial teórico del aprendizaje profundo y su viabilidad práctica en contextos clínicos reales.

En respuesta a esta problemática, se han propuesto estrategias alternativas como el aprendizaje no supervisado, auto supervisado y por transferencia, con el propósito de reducir la dependencia de datos etiquetados. Sin embargo, estos enfoques aún enfrentan desafíos significativos, especialmente en términos de robustez y adaptabilidad frente a variaciones en los niveles de ruido, los proveedores de equipos y las regiones anatómicas estudiadas (Zhang et al., 2022). En contraste, los métodos algebraicos y estadísticos han demostrado una mayor estabilidad ante estas condiciones adversas, lo que explica su permanencia como herramientas fundamentales en la reconstrucción de imágenes médicas (Bustos, 2022).

En el ámbito específico de la detección y corrección de artefactos, los modelos basados en aprendizaje profundo han mostrado avances particularmente notables. Carrizales et al. (2024)

evidencian que el modelo AD2 permite identificar de manera eficiente múltiples tipos de artefactos en imágenes 4DCT, facilitando su posterior corrección y posicionándose como una herramienta prometedora en aplicaciones de radioterapia. De manera complementaria, Ko et al. (2021) presentan un enfoque basado en redes neuronales profundas con mecanismos de autoatención, capaz de manejar movimientos rígidos y no rígidos en tiempo real. En comparación con los métodos tradicionales de corrección geométrica, estas aproximaciones destacan por su capacidad para modelar relaciones no lineales complejas, inherentes a los artefactos de movimiento respiratorio.

No obstante, la superioridad de los modelos basados en inteligencia artificial no implica la obsolescencia de las técnicas clásicas. Bustos (2022) subraya que los métodos algebraicos y

estadísticos continúan ofreciendo una reducción significativa del ruido y los artefactos, además de permitir una disminución de la dosis de radiación al paciente al no requerir todas las proyecciones convencionales. En la misma línea, Hernández et al. (2021) demuestran que el método iterativo OSEM supera al algoritmo FBP en la corrección del endurecimiento del haz, logrando mejores niveles de contraste y relación señal-ruido, aunque a costa de un mayor esfuerzo computacional. Esta comparación pone de relieve un aspecto central: la mejora en la calidad de imagen suele implicar un incremento en la complejidad computacional, lo que condiciona la implementación clínica de estos métodos.

Desde la perspectiva del diagnóstico asistido por computadora (CAD), el aprendizaje profundo ha ampliado de manera sustancial las capacidades de análisis de imágenes médicas. Chan et al. (2020) destacan que estas herramientas pueden complementar la toma de decisiones clínicas, aumentando la precisión diagnóstica y optimizando los flujos de trabajo. Sin embargo, los autores advierten que su adopción depende de procesos rigurosos de validación, estandarización y formación del personal. En comparación con los sistemas CAD tradicionales, los modelos basados en Deep Learning ofrecen una mayor capacidad adaptativa, aunque requieren infraestructuras más complejas y marcos regulatorios claramente definidos.

En escenarios caracterizados por la disponibilidad limitada de datos, algunos estudios aportan evidencias especialmente relevantes. Yim et al. (2021) proponen una red neuronal profunda capaz de reconstruir imágenes de TC a partir de pocas vistas, superando a los métodos clásicos FBP y SART en precisión cuantitativa y reducción de ruido. De manera análoga, Zétera (2023) demuestra que la aplicación de redes neuronales convolucionales para la reducción de ruido en sinogramas mejora de forma sustancial la calidad de las imágenes finales. Sin embargo, estos resultados deben interpretarse con cautela, ya que la variabilidad interinstrumental y de

adquisición puede degradar significativamente el rendimiento de los modelos, como advierte Garrido (2019), limitando su generalización en entornos clínicos heterogéneos.

En este contexto, los enfoques híbridos emergen como una alternativa especialmente prometedora. Farhan et al. (2024) sostienen que la integración de métodos de aprendizaje automático, aprendizaje profundo y técnicas de optimización permite mejorar el desempeño global de los sistemas de análisis de imágenes médicas, al mitigar las debilidades inherentes de cada enfoque por separado. De forma similar, Zeng (2023) propone un algoritmo iterativo guiado por redes neuronales que logra una reducción significativa de los artefactos, aunque reconoce limitaciones relacionadas con la no convexidad de la función objetivo y la convergencia a mínimos local.

Por otro lado, el análisis de la evidencia técnica identifica que la fidelidad diagnóstica se ve comprometida por distorsiones intrínsecas a la física del equipo y factores extrínsecos vinculados al paciente, los cuales no son simples errores visuales, sino anomalías que pueden simular patologías inexistentes o "falsos positivos" (Sartori et al., 2015; Arena & Morehouse, 1995). En la Tomografía Computarizada (TC), el endurecimiento del haz (beam hardening) y los artefactos metálicos surgen como las mayores barreras; estos últimos se producen cuando elementos de alta densidad, como prótesis o clips quirúrgicos, provocan una absorción total de la radiación, resultando en perfiles de proyección incompletos y la aparición de rayas fuertes o formas de estrella (Rodríguez-Gallo et al., 2018; Sartori et al., 2015; Camargo et al., 2023).

Estudios in vitro demuestran que materiales dentales y prótesis de cadera afectan significativamente la calidad de la imagen, oscureciendo estructuras anatómicas circundantes y dificultando el diagnóstico certero (Klinke et al., 2012; Rodríguez-Gallo et al., 2018). Por su parte, en la Resonancia Magnética (RM), la literatura subraya una alta sensibilidad al

movimiento y a la susceptibilidad magnética; fenómenos como el ghosting (imágenes fantasmas) y el aliasing (solapamiento) ocurren por desplazamientos de los protones de hidrógeno durante la adquisición o por campos de visión que no incluyen toda la anatomía, lo que genera réplicas difusas que desdibujan los contornos (Sartori et al., 2015; Caicedo et al., 2024; Arena & Morehouse, 1995).

Asimismo, la transición hacia la automatización diagnóstica se fundamenta en la capacidad de las Redes Neuronales Convolucionales (CNN) para extraer automáticamente patrones jerárquicos complejos a partir de los datos brutos, eliminando la necesidad de una extracción manual de características (Shen et al., 2017; Mazurowski et al., 2017). Dentro de las arquitecturas reportadas, la U-Net se consolida como el estándar para la reconstrucción en RM, dado que su estructura de codificador-decodificador con conexiones de salto permite recuperar información contextual mientras se preservan detalles locales, alcanzando precisiones del 93% en la detección y corrección de distorsiones de campo (Chen et al., 2023; Lozano et al., 2025; Estienne et al., 2020). Mientras, la arquitectura ResNet destaca en el manejo de distorsiones múltiples y complejas; al emplear conexiones residuales, evita la degradación de la señal en redes profundas, logrando un F1-score del 95% en la detección de objetos y eliminación de ruido estructural (Elhanashi et al., 2025; Lozano et al., 2025). Alternativamente, los autoencoders no supervisados emergen como una solución clave cuando se carece de grandes volúmenes de datos etiquetados, demostrando una eficacia del 45% en la reducción de ruido mediante el aprendizaje de representaciones latentes, lo que facilita la limpieza de imágenes sin intervención humana constante (Cui et al., 2019; Lozano et al., 2025).

En cuanto a la integración de modelos de Aprendizaje Profundo impacta directamente en la seguridad radiológica al permitir la mejora de la relación señal/ruido (SNR) y la reducción de

la dosis administrada al paciente. La literatura indica que el uso de estas redes puede reducir la dosis de radiación en TC entre un 19% y un 30% sin sacrificar la nitidez anatómica, lo que cumple estrictamente con el principio ALARA (As Low As Reasonably Achievable) al compensar la falta de fotones mediante algoritmos de reconstrucción avanzada (Arroyave Correa et al., 2025; Ramírez et al., 2010).

En el ámbito de la RM, se reporta que el uso de CNN con aprendizaje por transferencia logra disminuir en un 35% la necesidad de repetir exámenes debido a artefactos de movimiento, optimizando los tiempos de respuesta y reduciendo la incomodidad del paciente (Najjar, 2023; Shimron & Perlman, 2023). Cuantitativamente, la aplicación de CNN profundas en imágenes PET ha permitido reducir el ruido estructural en un 50%, mejorando la legibilidad de estructuras críticas en equipos modernos (Liu et al., 2021). Estos avances no solo garantizan diagnósticos más veraces, sino que también ofrecen una mejora sustancial en la eficiencia operativa de los servicios de imagenología al estandarizar la interpretación y eliminar la variabilidad del error humano (Velasco Hidalgo, 2015; Lozano et al., 2025; Caicedo et al., 2024).

A pesar de la eficacia técnica demostrada, la implementación efectiva de sistemas basados en IA enfrenta barreras críticas relacionadas con la infraestructura y la capacitación del personal. La falta de estandarización entre los sistemas de almacenamiento de imágenes (PACS/RIS) y la carencia de hardware de alto rendimiento (GPUs) limitan el despliegue de estos algoritmos en instituciones con recursos restringidos (Panayides et al., 2020; Lozano et al., 2025).

En el contexto colombiano, se documenta una brecha tecnológica significativa, pues se estima que solo el 32% de las instituciones públicas cuentan con equipos compatibles con sistemas de inteligencia artificial (Camargo, 2024). Operativamente, persiste una resistencia al

cambio y un temor hacia la tecnología, originados por la falta de comprensión sobre el funcionamiento de las redes neuronales y el fenómeno de la "caja negra", donde la toma de decisiones automática carece de transparencia (Lozano et al., 2025; Scott & De Cecco, 2020; Yordanova, 2024). Por ello, se concluye que la implementación ética y viable requiere una supervisión humana obligatoria que valide los resultados de la IA, además del cumplimiento riguroso de las normas de Habeas Data mediante la anonimización de datos clínicos para proteger la privacidad de los pacientes (Scott & De Cecco, 2020; Lozano et al., 2025; Delgado Orozco et al., 2024).

Con la investigación anterior, se llega a la respuesta del interrogante planteado en un principio sobre la eficacia de las redes neuronales, coincidiendo en que, particularmente las Redes Neuronales Convolucionales, presentan una elevada eficacia en la detección y mitigación de artefactos en imágenes médicas, alcanzando en numerosos estudios precisiones superiores al 90 % en tareas de reconstrucción y mejora de la calidad diagnóstica. Esta efectividad depende en gran medida de la arquitectura empleada y del tipo de distorsión a corregir, siendo especialmente notable en Tomografía Computarizada, donde las redes neuronales han demostrado un alto rendimiento frente al endurecimiento del haz, el ruido estructural y los artefactos metálicos que suelen ocultar detalles anatómicos relevantes y dificultar la interpretación clínica. En este contexto, modelos como ResNet, combinados con estrategias de detección avanzadas como YOLOv8, han reportado valores de F1-score cercanos al 95 % en la eliminación de ruido y la identificación de estructuras complejas, mientras que el uso de autoencoders no supervisados ha permitido reducir el ruido hasta en un 45 % sin requerir grandes volúmenes de datos etiquetados. De forma paralela, en Resonancia Magnética, la arquitectura U-Net se ha consolidado como un referente debido a su capacidad para integrar información contextual y preservar detalles locales,

logrando precisiones de hasta el 93 % en la reconstrucción de imágenes afectadas por movimientos involuntarios del paciente. La aplicación de estas tecnologías se traduce, además, en una optimización integral de la calidad de la imagen diagnóstica, ya que facilita el cumplimiento del principio ALARA al posibilitar estudios con dosis reducidas de radiación en TC sin sacrificar la nitidez anatómica, disminuye de manera significativa la necesidad de repetir exámenes con reducciones reportadas del 35 % en RM y mejora la fidelidad y sensibilidad de las imágenes mediante una diferenciación más precisa entre anatomía real y ruido técnico, alcanzando reducciones de hasta el 50 % del ruido estructural en imágenes de alta resolución.

Asimismo, la adopción de arquitecturas ligeras como MobileNet y EfficientNet ha evidenciado una eficacia cercana al 91 % en la reducción de artefactos digitales, lo que amplía el acceso a diagnósticos de alta calidad incluso en centros con infraestructuras computacionales limitadas. Estos avances confirman que las redes neuronales no solo automatizan la detección de fallos susceptibles de generar falsos positivos, sino que también restauran la fidelidad espacial y de contraste de las imágenes médicas, contribuyendo de manera decisiva a diagnósticos más precisos, confiables y seguros.

## Conclusiones

La investigación permite concluir, desde un enfoque analítico, que la integración de Redes Neuronales Convolucionales en la práctica radiológica no representa únicamente una mejora estética de la imagen, sino una respuesta estructural a las limitaciones intrínsecas de la Tomografía Computarizada y la Resonancia Magnética. El análisis de la evidencia disponible confirma que arquitecturas especializadas, como U-Net y ResNet, poseen una capacidad superior para mitigar la distorsión anatómica y corregir artefactos complejos, alcanzando de manera consistente niveles de precisión superiores al 90 %. Esta efectividad se explica por la habilidad de las capas jerárquicas de las redes para discriminar entre ruido, señales espurias y morfología tisular real, lo que permite restaurar la fidelidad diagnóstica y reducir de forma significativa la aparición de falsos positivos que históricamente han comprometido la interpretación clínica.

Desde la perspectiva del impacto clínico, el uso de modelos de aprendizaje profundo redefine el cumplimiento del principio ALARA, al posibilitar una optimización proactiva de la dosis de radiación en estudios de TC sin comprometer la calidad de la imagen. A diferencia de los métodos convencionales de corrección, limitados por la intervención manual y la variabilidad humana, las redes neuronales permiten obtener estudios de alta calidad incluso bajo condiciones de adquisición subóptimas, como dosis reducidas o la presencia de movimiento del paciente. En Resonancia Magnética, la corrección automatizada de artefactos de movimiento e interferencias técnicas ha demostrado una disminución notable en la necesidad de repetir exámenes, lo que repercute directamente en la eficiencia operativa, la reducción de costos y la mejora de la experiencia del paciente.

En el plano institucional y operativo, el análisis muestra una brecha significativa entre el potencial de estas soluciones algorítmicas y la infraestructura tecnológica disponible, particularmente en contextos con recursos limitados. La disponibilidad restringida de hardware de alto rendimiento y la falta de estandarización de los sistemas de información en salud constituyen obstáculos relevantes para la implementación generalizada de la inteligencia artificial en radiología. En este escenario, la adopción de arquitecturas livianas y escalables se perfila como una alternativa viable, al permitir mantener altos niveles de eficacia con menores requerimientos computacionales, facilitando así su incorporación en instituciones que no cuentan con infraestructuras avanzadas.

Finalmente, desde una perspectiva ética y legal, la implementación de redes neuronales en el ámbito radiológico exige una alineación estricta con la protección de los datos personales y el derecho a la privacidad. La naturaleza opaca de algunos modelos de inteligencia artificial hace indispensable la supervisión humana continua y la validación técnica permanente por parte de profesionales capacitados, garantizando que la toma de decisiones asistida por algoritmos sea transparente, responsable y segura. En consecuencia, la transición hacia una radiología digital avanzada no solo demanda inversión tecnológica, sino también una redefinición de las competencias profesionales, orientada a integrar el juicio clínico con herramientas inteligentes, asegurando una atención ética, humanizada y centrada en el bienestar integral del paciente.

### Referencias Bibliográficas

- Arena, L., & Morehouse, H. T. (1995). *MR imaging artifacts that simulate disease: How to recognize and eliminate them*. *RadioGraphics*, 15(6), 1373–1394.  
<https://pubmed.ncbi.nlm.nih.gov/8577963/>
- Arias, F. G. (2012). *El proyecto de investigación: Introducción a la metodología científica* (6.<sup>a</sup> ed.). Editorial 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)
- Arroyave, E., et al. (2025). *Las redes neuronales y su impacto en la calidad de las imágenes de tomografía computarizada*. [Diplomado de profundización para grado]. Repositorio Institucional UNAD. <https://repository.unad.edu.co/handle/10596/68656>
- Barrett, J. F., & Keat, N. (2004). Artifacts in CT: Recognition and avoidance. *RadioGraphics*, 24(6), 1679–1691. <https://pubs.rsna.org/doi/abs/10.1148/rg.246045065>
- Buades, M., & González, A. (2013). Métricas que definen la calidad de imagen. En *Introducción al control de calidad en radiología digital* (pp. 43–83). Sociedad Española de Física Médica.  
<https://proteccionradiologica.cl/wp-content/uploads/2016/08/8-2013-Control-de-calidad-en-Radiologia-Digital.pdf>
- Burbano, C. R., et al. (2024). *Calidad deficiente en las imágenes radiológicas por falta de mantenimiento preventivo en el equipo de rayos X*. [Diplomado de profundización para grado]. Repositorio Institucional UNAD. <https://repository.unad.edu.co/handle/10596/62832>
- Buzug, T. M. (2008). *Computed tomography: From photon statistics to modern cone-beam CT*. Springer.  
<https://eprints.poltekkesadisutjipto.ac.id/id/eprint/2084/1/Buzug%20T.M.->

Computed%20tomography %20From%20photon%20statistics%20to%20modern%20con  
e-beam%20CT-Springer%20%282008%29.pdf

Caicedo, A. M., *et al.* (2024). *Detección y corrección de artefactos en tomografía Computarizada, resonancia magnética y ecografía*. [Diplomado de profundización para grado]. Repositorio Institucional UNAD. <https://repository.unad.edu.co/handle/10596/62091>

Calzado, A., & Geleijns, J. (2010). Tomografía computarizada: Evolución, principios técnicos y aplicaciones. *Revista de Física Médica*, 11(3).  
<https://revistadefisicamedica.es/index.php/rfm/es/article/view/115/115>

Camargo, D. P., *et al.* (2024). *Artefactos y artificios en tomografía computada*. [Diplomado de profundización para grado]. Repositorio Institucional UNAD.  
<https://repository.unad.edu.co/handle/10596/60195>

Cervantes, R. (2018). *Evaluación de artefactos en imágenes radiográficas digitales procedentes de equipo radiológico computarizado vs. equipo digital directo* [Tesis de posgrado, Universidad Nacional Federico Villarreal]. <https://repositorio.unfv.edu.pe/items/0a492bfl-1c55-4aef-ae77-c23c13ab0ebd>

Chan, H.-P., Samala, R. K., Hadjiiski, L., & Zhou, Z. (2020). Deep learning in computer- aided diagnosis: Advances and challenges. *Journal of Digital Imaging*, 33(4), 1004–1018.  
<https://doi.org/10.1007/s10278-019-00296-8>

Chen, Z., Pawar, K., Ekanayake, M., Pain, C., Zhong, S., & Egan, G. (2023). Deep learning for MRI image enhancement and correction: State of the art and challenges. *Journal of Digital Imaging*, 36(2), 478–495. <https://doi.org/10.1007/s10278-022-00721-9>

Elhanashi, A., Saponara, S., Zheng, Q., Almutairi, N., Singh, Y., Kuanar, S., Ali, F., Unal, O., & Faghani, S. (2025). AI-based object detection in radiology: Current models, challenges, and future. *Journal of Imaging*, 11(5), 141. <https://doi.org/10.3390/jimaging11050141>

Estienne, T., Lerousseau, M., Vakalopoulou, M., Alvarez Andres, E., Battistella, E., Carré, A., Chandra, S., Christodoulidis, S., Sahasrabudhe, M., Sun, R., Robert, C., Talbot, H., Paragios, N.,

& Deutsch, E. (2020). Deep learning-based concurrent brain registration and tumor segmentation.

*Frontiers in Computational Neuroscience*, 14, 17. <https://doi.org/10.3389/fncom.2020.00017>

Farhan, A., Malik, T., & Raza, M. (2024). *Hybrid models and integrated optimization in medical image*

*analysis systems*. <https://jscca.uotechnology.edu.iq/jscca/vol1/iss2/3/>

Flórez, J., et al. (2008). *Redes neuronales artificiales: Fundamentos teóricos y aplicaciones prácticas*.

Nebiblo. Universidad de Sevilla.

[https://fama.us.es/discovery/fulldisplay?docid=alma991008164469704987&context=L&](https://fama.us.es/discovery/fulldisplay?docid=alma991008164469704987&context=L&vid=34CBUA_US:VU1&lang=es&adaptor=Local%20Search%20Engine&tab=all_data_not_id)

[vid=34CBUA\\_US:VU1&lang=es&adaptor=Local%20Search%20Engine&tab=all\\_data\\_not\\_id](https://fama.us.es/discovery/fulldisplay?docid=alma991008164469704987&context=L&vid=34CBUA_US:VU1&lang=es&adaptor=Local%20Search%20Engine&tab=all_data_not_id)

[us](https://fama.us.es/discovery/fulldisplay?docid=alma991008164469704987&context=L&vid=34CBUA_US:VU1&lang=es&adaptor=Local%20Search%20Engine&tab=all_data_not_id)

Gómez, D. C., et al. (2024). *Contribución de la Radiología Digital al Mejoramiento de la Calidad en el*

*Servicio de Imagenología*. [Diplomado de profundización para grado]. Repositorio Institucional

UNAD. <https://repository.unad.edu.co/handle/10596/63206>

Hernández Sampieri, R., Fernández Collado, C., & Baptista Lucio, P. (2014). *Metodología de la*

*investigación* (6.<sup>a</sup> ed.). McGraw-Hill Education.

[https://apiperiodico.jalisco.gob.mx/api/sites/periodicooficial.jalisco.gob.mx/files/metodol](https://apiperiodico.jalisco.gob.mx/api/sites/periodicooficial.jalisco.gob.mx/files/metodologia_de_la_investigacion_-_roberto_hernandez_sampieri.pdf)

[ogia\\_de\\_la\\_investigacion\\_-\\_roberto\\_hernandez\\_sampieri.pdf](https://apiperiodico.jalisco.gob.mx/api/sites/periodicooficial.jalisco.gob.mx/files/metodologia_de_la_investigacion_-_roberto_hernandez_sampieri.pdf)

Hernández, D., López, M., & Rivera, J. (2021). *Reconstrucción iterativa y corrección de endurecimiento*

*de haz mediante OSEM en imágenes médicas*.

<https://www.redalyc.org/journal/3783/378367420006/html/>

Ko, E., Nakamura, K., & Huang, S. (2021). Motion artifact correction in computed tomography using

deep convolutional neural networks with self-attention. *Physics in Medicine & Biology*, 66(12).

<https://doi.org/10.1088/1361-6560/abf9d3>

Lozano, B. E., Lambraño Celis, H. J., Sierra Díaz, M. P., Rincón Tarazona, N. F., & Quiroz Pérez, Y. M.

(2025). *Detección y corrección automática de artefactos en imágenes médicas utilizando redes neuronales para identificar y mejorar la precisión diagnóstica*.

<https://repository.unad.edu.co/jspui/bitstream/10596/77924/3/Jpriveraf%20.pdf>

- Matich, D. J. (2001). *Redes neuronales: Conceptos básicos y aplicaciones*. Universidad Tecnológica Nacional.  
[https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5\\_anio/orientadora1/monogriais/matich-redesneuronales.pdf](https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5_anio/orientadora1/monogriais/matich-redesneuronales.pdf)
- Minsky, M., & Papert, S. (1969). *Perceptrons*. <https://rodsmith.nz/wp-content/uploads/Minsky-and-Papert-Perceptrons.pdf>
- Muñoz, D. F., et al. (2024). *Propuesta de guía para la detección y corrección de artificios en estudios de tomografía computarizada*. [Diplomado de profundización para grado].  
 Repositorio Institucional UNAD. <https://repository.unad.edu.co/handle/10596/60187>
- Ortega, J. J., et al. (2024). *Fundamentos de la calidad de imagen en radiología digital*. [Diplomado de profundización para grado]. Repositorio Institucional UNAD.  
<https://repository.unad.edu.co/handle/10596/65576>
- Ortiz, P., Sartori, P., & Griensu, A. (2015). Artefactos y artificios frecuentes en tomografía computada y resonancia magnética. *Revista Argentina de Radiología*, 79(4), 192–204.  
<https://www.elsevier.es/es-revista-revista-argentina-radiologia-383-articulo-artefactos-artificios-frecuentes-tomografia-computada-S0048761915000794>
- Ramírez, J. C., Fletcher, J. J., & McCollough, C. H. (2010). Reducción del ruido en imágenes de tomografía computarizada usando un filtro bilateral anisotrópico. *Revista Ingeniería Biomédica*, 4(7), 55–62. [http://www.scielo.org.co/scielo.php?script=sci\\_arttext&pid=S1909-97622010000100007](http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S1909-97622010000100007)
- Rodríguez-Gallo, Y., Orozco-Morales, R., & Pérez-Díaz, M. (2018). Methods for reducing metal artifacts in computerized tomography. *Nucleus*, (65), 11–29.  
[http://scielo.sld.cu/scielo.php?script=sci\\_arttext&pid=S0864-084X2019000100011](http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S0864-084X2019000100011)
- Sartori, P., Rozowykniat, M., Siviero, L., Barba, G., Peña, A., Mayol, N., Acosta, D., Castro, J., & Ortiz, A. (2015). Artefactos y artificios frecuentes en tomografía computada y resonancia magnética. *Revista Argentina de Radiología*, 79(4), 192–204.

<https://doi.org/10.1016/j.rard.2015.04.005>

Shen, D., Wu, G., & Suk, H. I. (2017). Deep learning in medical image analysis. *Annual Review of Biomedical Engineering*, 19, 221–248. <https://pubmed.ncbi.nlm.nih.gov/28301734/>

Shimron, E., & Perlman, O. (2023). AI in MRI: Computational frameworks for a faster, optimized, and automated imaging workflow. *Bioengineering*, 10(4), 492.  
<https://doi.org/10.3390/bioengineering10040492>

Subias, J. C., & Jerez, J. A. (2015). *Tomografía computarizada dirigida a técnicos superiores en imagen para el diagnóstico*. Elsevier. <https://shop.elsevier.com/books/tomografia-computarizada-dirigida-a-tecnicos-superiores-en-imagen-para-el-diagnostico/costa-subias/978-84-1382-884-8>

Velasco Hidalgo, F. (2015). *Impacto de la radiología digital en la dosis de referencia de la radiología intraoral española* [Tesis doctoral, Universidad de Murcia].  
<https://share.google/qG0WMd3JRJMtjp02u>

Yim, K., Park, J., & Seo, Y. (2021). Computed tomography reconstruction from few-view data using deep convolutional neural networks. *Physics in Medicine & Biology*, 66(4).  
<https://doi.org/10.1088/1361-6560/abd6a3>

Yordanova, M. Z. (2024). The applications of artificial intelligence in radiology: Opportunities and challenges. *European Journal of Medicine*, 6(2).  
<https://www.semanticscholar.org/reader/6b7af0c9822b2008ea06c084b79c533267f7c4b2>

Yuya Onishi (2024). *Reducción de ruido en sinogramas y reconstrucción mejorada mediante redes neuronales convolucionales*. <https://link.springer.com/article/10.1007/s12194-024-00780-3>

Zeng, L. (2023). *Iterative sinogram-domain reconstruction guided by neural networks for artifact reduction in medical images*. <https://pmc.ncbi.nlm.nih.gov/articles/PMC10529507/>

Zhang, X., Liu, Y., Wang, H., & Chen, J. (2022). Applications and limitations of machine learning in low-dose computed tomography reconstruction. *IEEE Transactions on Medical Imaging*.  
<https://link.springer.com/article/10.1007/s40747-022-00724-7>