

**Artefactos en imágenes radiológicas digitales: uso de redes neuronales profundas para la  
mejora de la calidad diagnóstica**

Alejandra Arcila Rios

Jonathan Cossio Vargas

Iván Darío Moreno Caro

Luz Meris Palacios

Ricardo Vélez Castaño

Asesor

Javier Alberto Pérez Murillas

Universidad Nacional Abierta y a Distancia UNAD

Escuela de Ciencias de la Salud - ECISA

Radiología e Imágenes Diagnosticas

2025

## Resumen

La presente propuesta de investigación tiene como objetivo analizar el uso de redes neuronales profundas como una herramienta de apoyo en la detección y corrección automática de artefactos en imágenes médicas, buscando mejorar la calidad diagnóstica y disminuir la repetición innecesaria de estudios radiológicos. Este estudio se desarrolla bajo un enfoque cualitativo, descriptivo y documental, sustentado en la revisión de literatura científica reciente relacionada con la inteligencia artificial aplicada al procesamiento de imágenes médicas, especialmente en modalidades como la resonancia magnética, la tomografía computarizada y los rayos X. A través del análisis de modelos existentes, se pretende formular una propuesta de integración clínica que responda al rol del Tecnólogo en Imágenes Diagnósticas, fortaleciendo su participación en los procesos de optimización de la calidad de imagen antes de la interpretación por parte del médico radiólogo. El propósito esencial es demostrar que las herramientas basadas en inteligencia artificial no sustituyen la labor humana, sino que la complementan, promoviendo la seguridad del paciente, la eficiencia asistencial y la excelencia en el diagnóstico médico.

***Palabras clave:*** Artefactos, Redes Neuronales, Inteligencia Artificial, Calidad Diagnóstica.

### **Abstract**

The present research proposal aims to analyze the use of deep neural networks as a support tool for the automatic detection and correction of artifacts in medical images, seeking to improve diagnostic quality and reduce unnecessary repetition of radiological studies. This study is developed under a qualitative, descriptive, and documentary approach, based on a review of recent scientific literature related to artificial intelligence applied to medical image processing, particularly in modalities such as magnetic resonance imaging, computed tomography, and X-ray imaging. Through the analysis of existing models, this work seeks to formulate a proposal for clinical integration that addresses the role of the Diagnostic Imaging Technologist, strengthening their participation in image quality optimization processes prior to interpretation by the radiologist. The essential purpose is to demonstrate that artificial intelligence-based tools do not replace human expertise, but rather complement it, promoting patient safety, healthcare efficiency, and excellence in medical diagnosis.

**Keywords:** Artifacts, Deep Neural Networks, Artificial Intelligence, Medical Imaging, Diagnostic Quality.

## Tabla de Contenido

Introducción .....	8
Planteamiento del problema.....	10
Justificación .....	12
Objetivos .....	14
Objetivo General.....	14
Objetivos Específicos .....	14
Marco Teórico.....	15
Historia de la Radiología .....	15
Radiología digital y control de calidad.....	17
Artefactos en imágenes médicas.....	18
Métodos tradicionales de detección y corrección.....	19
Inteligencia artificial en imágenes médicas.....	20
Tipos de inteligencia artificial utilizados en la corrección de artefactos.....	20
Concepto de calidad de imagen en radiología digital.....	21
Definición de artefacto .....	21
Métodos de corrección y mitigación de artefactos .....	22
Técnicas de posprocesamiento .....	22
Optimización de parámetros de adquisición.....	22
Detección y reconstrucción automática mediante Deep Learning.....	23
Impacto en la Gestión hospitalaria .....	23

Calidad de imagen y seguridad del paciente.....	23
Impacto económico.....	23
Marco metodológico .....	24
Población y muestra.....	24
Técnicas de recolección de información .....	24
Instrumentos .....	25
Fases del estudio .....	25
Recolección de información .....	25
Análisis .....	25
Conclusión aplicada.....	25
Resultados .....	26
Avances en detección de artefactos mediante redes neuronales profundas.....	26
Corrección automática de artefactos y recuperación de la anatomía.....	27
Hallazgos de impacto clínico en modalidades especializadas.....	28
Impacto en el flujo de trabajo y experiencia del paciente .....	29
Conclusiones.....	36
Referencias bibliográficas.....	38

**Lista de Tablas**

**Tabla 1** *Papel de Redes Neuronales en su Detección de Artefactos* ..... 30

**Tabla 2** *Comparativo Internacional*..... 32

**Lista de Figuras**

<b>Figura 1</b> <i>Evolución de la Radiología</i> .....	17
---	----

## Introducción

La calidad de las imágenes diagnósticas constituye un elemento esencial para garantizar interpretaciones precisas y una atención médica segura. No obstante, uno de los problemas más comunes en la práctica radiológica es la presencia de artefactos, los cuales pueden surgir por múltiples causas, como el movimiento involuntario del paciente, fallas técnicas, mantenimiento inadecuado del equipo o errores en la técnica de adquisición. Estos artefactos pueden distorsionar la imagen, dificultar la visualización de estructuras anatómicas y conducir tanto a interpretaciones equivocadas como a la necesidad de repetir el examen. Esto no solo prolonga los tiempos de atención, sino que también incrementa los costos operativos y expone al paciente a exploraciones adicionales que podrían evitarse.

Ante esta problemática, la búsqueda de soluciones eficientes ha impulsado el interés por la aplicación de la inteligencia artificial, especialmente de las redes neuronales profundas. Estas redes imitan el funcionamiento del cerebro humano mediante capas interconectadas capaces de aprender patrones complejos a partir de grandes volúmenes de datos. En el ámbito de las imágenes médicas, han demostrado un notable potencial para detectar, clasificar y corregir artefactos de manera automática, contribuyendo a restaurar la nitidez y fidelidad de la imagen sin intervención manual. Su capacidad para identificar variaciones imperceptibles para el ojo humano las convierte en herramientas valiosas para optimizar la calidad de las imágenes en modalidades como la resonancia magnética, la tomografía computarizada y los rayos X.

En este contexto, el presente trabajo analiza cómo la integración de redes neuronales profundas puede apoyar al Tecnólogo en Imágenes Diagnósticas en la optimización de los estudios antes de su interpretación por el médico radiólogo. Lejos de reemplazar la labor humana, estas tecnologías complementan y fortalecen los procesos clínicos, promoviendo mayor

seguridad para el paciente, eficiencia asistencial y excelencia en los resultados diagnósticos. De este modo, se destaca la importancia de estudiar su impacto y viabilidad para avanzar hacia prácticas radiológicas más precisas, seguras y tecnológicamente actualizadas.

## Planteamiento del Problema

En el contexto actual de constante transformación social, tecnológica y económica, resulta fundamental analizar los factores que inciden en la calidad de los servicios de salud, entre ellos la calidad de los estudios de imagen médica, los cuales constituyen una herramienta esencial para el diagnóstico clínico. No obstante, la presencia de artefactos en estudios de imagenología, como la resonancia magnética, la tomografía computarizada y el ultrasonido, puede comprometer significativamente la fiabilidad diagnóstica. Estos artefactos pueden ocultar lesiones, simular patologías inexistentes o deformar la anatomía de los órganos, dificultando la correcta interpretación médica (Barrett & Keat, 2004; Krupa & Bekiesińska-Figatowska, 2015).

La aparición de artefactos en las imágenes médicas responde a múltiples causas, entre las que se incluyen el movimiento del paciente durante la adquisición del estudio, fallas técnicas o mantenimiento inadecuado de los equipos, así como errores en la configuración de los parámetros de adquisición. Estudios en tomografía computarizada han demostrado que ciertos artefactos pueden degradar la calidad de la imagen hasta volverla “diagnósticamente inutilizable” (Boas, 2013), mientras que en resonancia magnética el movimiento del paciente puede generar distorsiones de señal que confunden la interpretación clínica (Smith & Nayak, 2015).

Las consecuencias de esta problemática se reflejan directamente en el proceso diagnóstico, ya que el personal médico puede incurrir en interpretaciones erróneas o verse obligado a solicitar la repetición del examen. Esto implica un aumento en los tiempos de atención, mayores costos para el sistema de salud y, en algunos casos, una exposición innecesaria del paciente a nuevas exploraciones. Además, los errores asociados a la presencia de artefactos pueden afectar la eficacia del tratamiento, la seguridad del paciente y la eficiencia de los servicios de salud.

Ante este panorama, resulta necesario explorar estrategias que permitan identificar y corregir los artefactos de manera oportuna, garantizando la fiabilidad de las imágenes médicas y fortaleciendo la calidad diagnóstica. En este sentido, los avances en inteligencia artificial, particularmente el uso de redes neuronales profundas aplicadas al procesamiento de imágenes médicas, han demostrado un creciente potencial como herramientas de apoyo para la detección y corrección automática de artefactos, lo que plantea nuevas posibilidades para optimizar los procesos diagnósticos. A partir de lo anterior, surge la siguiente pregunta de investigación:

¿Cómo contribuyen las redes neuronales profundas a la detección y corrección de artefactos en imágenes radiológicas digitales y a la mejora de la calidad diagnóstica, según la evidencia reportada en la literatura científica?

## Justificación

La relevancia de abordar el estudio de los artefactos en las imágenes radiológicas digitales radica en que la calidad de estas constituye un elemento esencial para la precisión de los diagnósticos clínicos y la adecuada toma de decisiones en salud. La presencia de errores, distorsiones o interferencias visuales puede dificultar la interpretación de las imágenes, aumentar el riesgo de diagnósticos equivocados y, en consecuencia, afectar de manera directa la atención y seguridad del paciente. Además, los artefactos suelen generar la repetición de estudios, lo que implica mayor exposición a radiación, incremento de costos y sobrecarga en los servicios de imagenología.

En este contexto, la investigación resulta relevante a nivel general, ya que analiza alternativas tecnológicas innovadoras orientadas a mejorar la calidad diagnóstica de las imágenes médicas. El uso de redes neuronales profundas se ha consolidado como una herramienta prometedora para la detección y corrección de artefactos, permitiendo optimizar los procesos de adquisición y posprocesamiento de imágenes sin afectar la información clínica esencial. Estas tecnologías contribuyen a la obtención de estudios más claros y confiables, favoreciendo diagnósticos oportunos y reduciendo la necesidad de repetir exámenes.

Desde un aporte científico, esta investigación permite sistematizar y analizar la evidencia reportada en la literatura sobre la aplicación de redes neuronales profundas en la corrección de artefactos, fortaleciendo el conocimiento existente en el área de la radiología digital y la inteligencia artificial aplicada a la salud. Diversos estudios han demostrado que modelos basados en redes neuronales, como arquitecturas tipo S-Net o encoder–decoder, logran corregir artefactos de movimiento, ruido y distorsiones en modalidades como la resonancia magnética, manteniendo altos niveles de precisión diagnóstica (Lyu et al., 2020; Jin et al., 2020; Lee et al., 2020).

En el ámbito social y profesional, los resultados de esta revisión aportan al mejoramiento de la calidad de la atención en salud, al promover el uso de tecnologías que favorecen diagnósticos más seguros y eficientes. Para los tecnólogos en radiología y demás profesionales del área, el estudio proporciona una base conceptual actualizada que facilita la comprensión del impacto de la inteligencia artificial en la práctica clínica. A nivel local, este trabajo contribuye a fortalecer la formación académica y la toma de decisiones informadas sobre la implementación progresiva de herramientas basadas en redes neuronales en los servicios de imagenología, en concordancia con las necesidades reales del sistema de salud.

## **Objetivos**

### **Objetivo General**

Analizar la evidencia científica sobre el uso de redes neuronales profundas en la corrección de artefactos para la optimización de la experiencia del paciente en los servicios de diagnóstico por imágenes.

### **Objetivos Específicos**

Identificar el impacto clínico que generan los artefactos de imagen en el paciente, específicamente en relación con la repetición de estudios y el aumento de la ansiedad.

Describir las capacidades técnicas de las redes neuronales profundas descritas en la literatura para la reducción de artefactos y la optimización de los tiempos de adquisición.

Evaluar los beneficios de la implementación de estas tecnologías en la humanización de la atención, considerando la seguridad del paciente y la agilidad de los servicios de salud.

## Marco Teórico

### Historia de la Radiología

La evolución de la radiología constituye un elemento fundamental para comprender los avances tecnológicos que sustentan los actuales sistemas digitales de adquisición y procesamiento de imágenes. Desde el descubrimiento de los rayos X por Wilhelm Conrad Roentgen en 1895, la obtención de imágenes diagnósticas ha transitado por diversos momentos históricos que han transformado la práctica clínica y los requerimientos de calidad en los servicios de radiología (Bansal, 2006; Seibert, 2006).

En sus inicios, la radiología se basaba en la radiografía convencional, un sistema analógico que utilizaba películas fotosensibles y procesos químicos para la revelación. Aunque este método permitió los primeros diagnósticos por imagen, presentaba limitaciones significativas relacionadas con el contraste, la resolución espacial, la sensibilidad del receptor y el deterioro físico de las placas (Seeram, 2008). Asimismo, los protocolos de control de calidad eran principalmente mecánicos y dependían de la inspección manual y del estado físico de los equipos.

A partir de la década de 1970, la introducción de la tomografía computarizada (TC) y la resonancia magnética (RM) marcó el inicio de la integración entre imagen médica y computación. Estos sistemas incorporaron detectores electrónicos y procesamiento digital, permitiendo la reconstrucción de imágenes en cortes y una mayor precisión diagnóstica. La transición hacia tecnologías computarizadas sentó las bases conceptuales para la digitalización completa de la radiología (Azevedo-Marques & Carvalho, 2021).

Durante los años 90 surgió la radiografía computarizada (CR), la cual reemplazó la película por placas de fósforo fotostimulable. Este cambio permitió almacenar, procesar y


transmitir las imágenes de manera digital sin alterar drásticamente el flujo de trabajo clínico. Posteriormente, la radiografía digital directa (DR) incorporó detectores planos basados en silicio o seleniuro, lo que eliminó la necesidad de placas intermedias y mejoró significativamente la eficiencia, la calidad de imagen y la reducción de dosis al paciente (Hammerström, 2015).

La consolidación de los sistemas PACS (Picture Archiving and Communication System) permitió organizar, archivar y distribuir las imágenes dentro de redes hospitalarias, optimizando su disponibilidad y su integración con los sistemas de información clínica (American College of Radiology, 2017). Esta digitalización completa no solo transformó la práctica radiológica, sino que también generó nuevas necesidades en términos de calibración, estandarización, manejo de artefactos y control de calidad.

En la actualidad, la radiología digital se articula con herramientas avanzadas de procesamiento, como algoritmos de reducción de ruido, reconstrucción iterativa y modelos basados en inteligencia artificial. Sin embargo, pese a los avances, persisten desafíos relacionados con la detección automática de artefactos, la coherencia del procesamiento digital, la dependencia de la calidad de los detectores y la necesidad de programas continuos de control técnico (IAEA, 2018; Chacón Jiménez, 2025). Comprender esta evolución histórica permite contextualizar la importancia de la modernización de los equipos, la gestión adecuada de los parámetros de exposición y la implementación de estándares internacionales en control de calidad.

## Figura 1

*Evolución Tecnológica de la Radiología Desde los Sistemas Analógicos Hasta La Digitalización Actual*



*Nota.* Evolución tecnológica de la radiología. Elaboración Propia.

### **Radiología Digital y Control de Calidad**

La radiología digital ha permitido una mejora sustancial en la adquisición, almacenamiento y distribución de imágenes diagnósticas, al reemplazar los sistemas analógicos por detectores digitales capaces de transformar la radiación ionizante en señales eléctricas que posteriormente son convertidas en imágenes digitales. El principio físico de la radiología digital se basa en la interacción de los rayos X con los tejidos del cuerpo humano, donde la atenuación diferencial de la radiación es captada por detectores digitales, ya sean de tipo indirecto o directo. Estos detectores convierten la energía de los rayos X en cargas eléctricas que son procesadas mediante sistemas informáticos, generando imágenes con una amplia escala de grises y mayor capacidad de posprocesamiento.

En este contexto, el control de calidad en radiología digital no se limita únicamente a la revisión de los parámetros técnicos de adquisición, como el kilovoltaje, miliamperaje y tiempo de exposición, sino que también contempla la evaluación del desempeño de los sistemas de hardware y software involucrados en la formación de la imagen. Entre los criterios de calidad más relevantes se encuentran la resolución espacial, la resolución de contraste, el nivel de ruido,

la uniformidad de la imagen y la correcta visualización de las estructuras anatómicas de interés. El cumplimiento de estos criterios es fundamental para garantizar imágenes diagnósticas confiables, reducir la necesidad de repeticiones de estudios y minimizar la dosis de radiación al paciente, contribuyendo así a una práctica radiológica segura y eficiente.

### **Artefactos en Imágenes Médicas**

Los artefactos son distorsiones, alteraciones o elementos no deseados que aparecen en las imágenes radiológicas y que no corresponden a la anatomía real del paciente. Estos pueden tener su origen en diversos factores, como errores técnicos durante la adquisición de la imagen, movimientos involuntarios del paciente, fallos en los equipos de imagenología o limitaciones propias de los sistemas digitales. La presencia de artefactos compromete la correcta interpretación clínica, disminuye la calidad de la imagen y reduce el valor diagnóstico del estudio, pudiendo conducir a diagnósticos erróneos o a la repetición innecesaria de los exámenes.

Entre los principales tipos de artefactos en radiología digital se encuentran los artefactos por movimiento, causados por la respiración, el temblor o la falta de inmovilización adecuada del paciente, los cuales generan imágenes borrosas y pérdida de nitidez. Asimismo, los artefactos por ruido se producen por una baja relación señal-ruido, generalmente asociada a dosis de radiación insuficientes o a fallas en el procesamiento digital, lo que afecta la visualización de estructuras anatómicas finas.

Otro tipo relevante corresponde a los artefactos metálicos, originados por la presencia de prótesis, implantes, dispositivos médicos o cuerpos extraños metálicos, los cuales provocan distorsiones, bandas o zonas de alta densidad que dificultan la evaluación de los tejidos circundantes. De igual forma, los artefactos por errores de adquisición o procesamiento pueden

deberse a configuraciones inadecuadas del equipo, calibraciones deficientes del detector o fallos en los algoritmos de reconstrucción de la imagen.

La identificación y comprensión de los diferentes tipos de artefactos y de sus causas resulta fundamental para implementar estrategias de control de calidad en radiología digital. Esto permite optimizar los parámetros de adquisición, mejorar el desempeño de los equipos y reducir la incidencia de imágenes no diagnósticas, favoreciendo así una práctica clínica más segura, eficiente y orientada a la calidad diagnóstica.

### **Métodos Tradicionales de Detección y Corrección**

Los métodos tradicionales o convencionales para la detección y corrección de artefactos en radiología digital se fundamentan en la experiencia del profesional y en la aplicación de procedimientos técnicos durante la adquisición y el procesamiento de la imagen. Uno de los métodos más utilizados corresponde al ajuste de los parámetros técnicos de exposición, como el kilovoltaje, el miliamperaje y el tiempo de exposición, los cuales influyen directamente en el contraste, el nivel de ruido y la nitidez de la imagen. Una adecuada selección de estos parámetros contribuye a mejorar la calidad de la imagen y a reducir artefactos asociados a una exposición inadecuada.

Otro método común es el uso de dispositivos de inmovilización, cuyo propósito es minimizar los movimientos involuntarios del paciente durante la adquisición del estudio. Esta práctica permite disminuir los artefactos por movimiento, los cuales afectan la nitidez y dificultan la correcta visualización de las estructuras anatómicas.

La repetición del estudio radiológico se emplea cuando la imagen obtenida no cumple con los criterios mínimos de calidad diagnóstica debido a la presencia de artefactos. Aunque esta medida puede mejorar el resultado final, implica un incremento en la dosis de radiación al

paciente y en el tiempo del procedimiento, por lo que se considera una solución correctiva y no ideal. asimismo, los procesos de posprocesamiento digital, como el ajuste manual de brillo, contraste y la aplicación de filtros básicos, se utilizan para optimizar la visualización de la imagen. Estos procedimientos pueden atenuar ciertos defectos visuales, pero su efectividad depende del operador y no siempre permite corregir el origen del artefacto. en conjunto, estos métodos convencionales contribuyen a la mejora de la calidad de las imágenes radiológicas; sin embargo, presentan limitaciones relacionadas con la variabilidad en los resultados y la dependencia del factor humano, lo que ha motivado el interés en estrategias automatizadas para la detección y corrección de artefactos.

### **Inteligencia Artificial en Imágenes Médicas**

La inteligencia artificial (IA) ha ganado protagonismo en la radiología por su capacidad de analizar grandes volúmenes de datos y reconocer patrones complejos. En imágenes médicas, la IA se aplica en la optimización de parámetros de exposición, detección de estructuras anatómicas, segmentación de lesiones y corrección de artefactos. Las redes neuronales profundas constituyen la base de estas aplicaciones, pues permiten un procesamiento avanzado similar a la visión humana.

### **Tipos de Inteligencia Artificial Utilizados en la Corrección de Artefactos**

En el ámbito de la radiología digital, los sistemas de inteligencia artificial más utilizados para la detección y corrección de artefactos se basan principalmente en técnicas de aprendizaje automático (Machine Learning) y aprendizaje profundo (Deep Learning). Dentro de estas, las redes neuronales convolucionales (CNN) son las más empleadas debido a su capacidad para analizar patrones espaciales en las imágenes médicas.

Estas redes funcionan a partir del entrenamiento con grandes conjuntos de imágenes previamente etiquetadas, lo que les permite aprender las características asociadas a imágenes de buena calidad y a distintos tipos de artefactos. Su funcionamiento se basa en capas jerárquicas que extraen información relevante de la imagen, como bordes, texturas y contrastes, facilitando la identificación automática de alteraciones no deseadas y la aplicación de procesos de corrección que mejoran la calidad diagnóstica

### **Concepto de Calidad de Imagen en Radiología Digital**

La calidad de la imagen radiológica es un elemento fundamental para garantizar una correcta interpretación diagnóstica. Esta se evalúa a partir de diversos parámetros, entre los cuales destacan la resolución espacial, el contraste, el ruido y la linealidad.

La resolución espacial hace referencia a la capacidad del sistema para distinguir estructuras pequeñas y cercanas entre sí, lo que permite una adecuada visualización de detalles anatómicos. El contraste se relaciona con la capacidad de diferenciar estructuras con distintas densidades o intensidades de señal. Por su parte, el ruido corresponde a las variaciones aleatorias que degradan la imagen y dificultan la identificación de detalles clínicamente relevantes. Finalmente, la linealidad describe la relación proporcional entre la señal registrada por el detector y la radiación incidente, siendo un factor clave para la fidelidad de la imagen.

### **Definición de Artefacto**

Un artefacto en imagen médica se define como una discrepancia entre los valores numéricos que componen la imagen digital y los coeficientes reales de atenuación o relajación de los tejidos representados. Estas discrepancias generan elementos visuales que no corresponden a la anatomía real del paciente y pueden interferir en la interpretación diagnóstica.

### **Clasificación General de los Artefactos**

De manera general, los artefactos pueden clasificarse según su origen en artefactos de origen físico, artefactos técnicos relacionados con el equipo y artefactos asociados al paciente. Los artefactos físicos se derivan de las limitaciones inherentes a los principios de formación de la imagen. Los artefactos técnicos se asocian a fallos en el equipo, calibraciones inadecuadas o errores de adquisición. Por último, los artefactos relacionados con el paciente suelen estar vinculados al movimiento, presencia de objetos metálicos o falta de cooperación durante el estudio.

## **Métodos de Corrección Y Mitigación de Artefactos**

### ***Técnicas de Posprocesamiento***

Entre los métodos más utilizados para la corrección de artefactos se encuentran las técnicas de posprocesamiento digital, las cuales incluyen filtros de reducción de ruido y algoritmos específicos como los algoritmos de corrección de artefactos metálicos (Metal Artifact Reduction, MAR). Estas técnicas buscan atenuar las distorsiones generadas por objetos metálicos y mejorar la uniformidad de la imagen, favoreciendo una mejor visualización de los tejidos adyacentes.

### ***Optimización de parámetros de adquisición***

La optimización de los parámetros de adquisición constituye otra estrategia fundamental para la mitigación de artefactos. El ajuste de variables como el tiempo de repetición (TR), el tiempo de eco (TE), el ancho de banda y la selección de secuencias específicas permite reducir la aparición de artefactos y mejorar la calidad general de la imagen, especialmente en modalidades como la resonancia magnética.

## **Redes Neuronales Artificiales Aplicadas a la Imagenología**

Las redes neuronales artificiales (RNA) están compuestas por capas interconectadas de nodos que procesan información de manera similar al sistema nervioso humano. En imagenología médica, estas arquitecturas permiten analizar grandes volúmenes de datos y aprender patrones complejos asociados a imágenes normales y patológicas.

### ***Detección y reconstrucción automática mediante Deep Learning***

El uso de técnicas de Deep Learning ha permitido avanzar en la detección automática de artefactos y en la reconstrucción de imágenes de mayor calidad. Estos modelos son capaces de eliminar ruido, corregir distorsiones y reconocer patrones anómalos de forma automática, reduciendo la dependencia del operador y aumentando la consistencia en la evaluación de la calidad de imagen.

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

#### ***Calidad de Imagen y Seguridad del Paciente***

La mejora en la detección y corrección de artefactos mediante inteligencia artificial contribuye al fortalecimiento de los criterios de calidad y seguridad del paciente. Una imagen de mayor calidad reduce el riesgo de diagnósticos erróneos, así como la probabilidad de falsos positivos o negativos, favoreciendo decisiones clínicas más precisas.

#### ***Impacto Económico***

Desde el punto de vista económico, la reducción en la repetición de estudios radiológicos y la optimización del mantenimiento preventivo de los equipos generan un impacto positivo en la gestión hospitalaria. La implementación de sistemas basados en inteligencia artificial permite disminuir costos asociados al uso innecesario de recursos, mejorar la eficiencia operativa y optimizar los tiempos de atención.

## **Marco Metodológico**

Este estudio se trabajará desde un enfoque cualitativo, ya que busca comprender cómo la corrección automática de artefactos mediante redes neuronales puede influir en la experiencia del paciente durante un estudio diagnóstico, especialmente en lo relacionado con repeticiones, tiempos de espera y comodidad.

El tipo de investigación será descriptiva y aplicada. Es descriptiva porque primero se revisan los principales artefactos que generan repeticiones de estudios y cómo estas situaciones pueden afectar al paciente en términos de tiempo, ansiedad o exposición innecesaria. Y es aplicada porque, a partir de esa revisión, se analiza el papel que tendrían las redes neuronales profundas como apoyo para mejorar la atención y hacerla más ágil y humana.

El diseño será documental, ya que se basa en la revisión de artículos científicos, estudios clínicos y reportes técnicos que explican tanto el impacto de los artefactos como los efectos positivos que ha tenido la introducción de herramientas de inteligencia artificial en los servicios de imágenes diagnósticas.

### **Población y Muestra**

La población estará conformada por artículos y publicaciones científicas relacionadas con artefactos, redes neuronales y experiencia del paciente en el contexto de imagenología. De esta población se seleccionará una muestra intencional, priorizando estudios recientes y relevantes que incluyan datos sobre repetición de exámenes, tiempos de atención o percepción del usuario.

### **Técnicas de Recolección de Información**

La técnica de recolección será la revisión bibliográfica sistematizada, utilizando bases de datos como PubMed, Scopus, ScienceDirect y Google Scholar. Se emplearán palabras clave relacionadas tanto con IA como con experiencia del paciente, tales como:

“patient experience in imaging”, “artifact correction AI”, “deep learning quality improvement”, “repeat scans patient impact”, “medical imaging workflow AI”.

### **Instrumentos**

El instrumento principal será una matriz de análisis documental, donde se organizará la información extraída de cada artículo: modalidad de imagen, tipo de artefacto, consecuencias para el paciente, solución basada en IA utilizada y resultados sobre la atención o tiempos de examen.

### **Fases del Estudio**

Basándonos en objetivos planteados se desarrollaría en las siguientes fases,

#### ***Recolección de Información***

Búsqueda de literatura científica enfocada tanto en artefactos como en su relación con la experiencia del paciente.

#### ***Análisis***

Clasificación y comparación de los estudios para identificar cómo la IA ha reducido repeticiones y tiempos, y qué modelos han sido más efectivos.

#### ***Conclusión Aplicada***

Reflexión y propuesta sobre cómo estas tecnologías pueden aportar a una atención más humanizada desde el rol del Tecnólogo en Imágenes Diagnósticas.

## **Resultados**

La revisión extensa de la literatura científica permitió identificar múltiples hallazgos relacionados con la presencia de artefactos en las imágenes diagnósticas y el papel actual de las redes neuronales profundas en su detección, clasificación y corrección automática. En términos generales, los estudios coinciden en que los artefactos continúan siendo una de las principales limitaciones para obtener imágenes diagnósticas confiables. Desde trabajos fundacionales hasta investigaciones contemporáneas, se reporta que los artefactos más frecuentes provienen del movimiento del paciente, ruido electrónico, interferencias metálicas y errores inherentes al proceso de adquisición (Barrett & Keat, 2004; Sartori, 2015). Estos elementos afectan la nitidez, el contraste, la estructura y la uniformidad de la imagen, dificultando la interpretación clínica y, en muchos casos, generando la necesidad de repetir estudios.

Se constató que estos artefactos no solo impactan la calidad diagnóstica, sino que prolongan los tiempos de atención, incrementan los costos asistenciales y afectan directamente la experiencia del paciente, quien debe someterse nuevamente a procedimientos que podrían evitarse si se contara con herramientas de corrección más eficaces. La acumulación de evidencia científica demuestra que la presencia de artefactos compromete la precisión diagnóstica en modalidades sensibles como la tomografía computarizada (TC) y la resonancia magnética (RM), especialmente en estudios de alta resolución o en zonas anatómicamente complejas.

### **Avances en Detección de Artefactos Mediante Redes Neuronales Profundas**

En relación con los aportes de las redes neuronales profundas, la revisión mostró que estas tecnologías han avanzado de manera significativa en la identificación automatizada de distintos tipos de artefactos. Algunos modelos han demostrado una notable capacidad para clasificar distorsiones de origen diverso, tales como artefactos por movimiento, por

susceptibilidad magnética, fallas de hardware o inconsistencias en el muestreo (Ettehadí et al., 2022). Asimismo, se halló que ciertos algoritmos basados en aprendizaje profundo pueden evaluar la calidad de la imagen antes de que el tecnólogo o el radiólogo realicen la inspección visual, permitiendo activar alertas tempranas y evitando que una imagen deficiente llegue al proceso de interpretación clínica (Fantini et al., 2021).

Este enfoque de análisis previo a la visualización representa un avance importante, ya que introduce un control de calidad automatizado capaz de detectar fallas que pudieran pasar desapercibidas en entornos de alta demanda, donde el personal suele manejar grandes volúmenes de estudios. La integración de IA en los sistemas PACS y en los flujos de trabajo hospitalarios permite, además, realizar diagnósticos más consistentes al minimizar la variabilidad asociada al factor humano.

### **Corrección Automática de Artefactos y Recuperación de la Anatomía**

Un aspecto especialmente relevante hallado en la literatura es que los modelos de deep learning no se limitan a identificar artefactos, sino que también pueden corregirlos con altos niveles de precisión. Investigaciones en tomografía computarizada muestran que redes neuronales convolucionales especializadas pueden reducir sustancialmente los artefactos metálicos asociados a prótesis, implantes dentales, tornillos ortopédicos u otros materiales radiopacos. Estos artefactos suelen producir distorsiones extensas en forma de líneas brillantes o sombras que dificultan la visualización anatómica y afectan la interpretación de lesiones adyacentes.

Estudios recientes revelan que la técnica DL-MAR es capaz de disminuir el error cuantitativo inducido por metal de  $\pm 10,5\%$  a tan solo  $\pm 1,3\%$  en PET/CT, lo cual implica una restauración casi completa de la anatomía y un enorme impacto clínico para diagnósticos de

precisión (Arabi & Zaidi, 2021). Este tipo de resultados demuestra que la IA no solo mejora la apariencia visual de la imagen, sino que corrige información cuantitativa relevante, esencial en estudios funcionales o de oncología, de manera similar, en resonancia magnética se han desarrollado modelos encoder–decoder capaces de eliminar artefactos por movimiento sin modificar la estructura anatómica real. Este avance es especialmente importante en poblaciones como niños, adultos mayores o pacientes con trastornos neurológicos, que presentan dificultad para permanecer inmóviles durante la adquisición. La mejora en índices como SSIM y PSNR en imágenes reconstruidas mediante deep learning respalda la utilidad clínica de estas herramientas (Cui et al., 2023).

### **Hallazgos de Impacto Clínico en Modalidades Especializadas**

La literatura también muestra que los efectos positivos de la IA van más allá de las imágenes convencionales. En modalidades cardiovasculares, especialmente en CCTA, las redes neuronales han demostrado mejorar la visualización de arterias coronarias afectadas por artefactos de pulsación o calcificación. Esto permite una evaluación más precisa del grado de estenosis, lo que repercute directamente en la selección de terapias y procedimientos (Jiang et al., 2024).

En estudios industriales y de alta energía aplicados a imágenes médicas, se han reportado mejoras significativas cuando se utilizan modelos dual-dominio combinados con arquitecturas UNet–ResNet, los cuales ofrecen restauraciones más detalladas y preservan bordes anatómicos que normalmente se distorsionan con métodos tradicionales (Jiang et al., 2024).

Además, investigaciones recientes han demostrado que la combinación de algoritmos MAR tradicionales con métodos de reconstrucción basados en IA mejora de manera sustancial la

calidad general de CT, incluso bajo parámetros de alta energía (kVp), permitiendo imágenes más consistentes y adaptadas a diferentes condiciones clínicas (Zou et al., 2025).

### **Impacto en el Flujo de Trabajo y Experiencia del Paciente**

Finalmente, múltiples artículos coinciden en que la incorporación de IA en el manejo de artefactos no reemplaza la labor del profesional, sino que la complementa. La automatización de la detección y corrección de errores reduce la carga operativa del tecnólogo y le permite dedicar más tiempo a funciones esenciales como la comunicación con el paciente, la preparación adecuada y la supervisión del procedimiento, factores determinantes en la calidad percibida del servicio.

La IA contribuye a disminuciones significativas en las repeticiones de estudios, lo que reduce la incomodidad del paciente, minimiza la exposición innecesaria a radiación en modalidades como TC y agiliza el flujo asistencial. Además, mejora la consistencia diagnóstica, disminuye la probabilidad de errores por imágenes subóptimas y permite que el proceso clínico se enfoque más en el acompañamiento humanizado (Obuchowicz et al., 2025).

En conjunto, los hallazgos revisados muestran que el uso de redes neuronales profundas tiene un impacto clínico real y significativo: mejora la calidad de imagen, fortalece el diagnóstico, optimiza los tiempos clínicos y contribuye a una experiencia de atención más segura, eficiente y centrada en el paciente.

**Tabla 1**

*Situaciones y Errores Comunes En Imágenes Diagnósticas y el Papel de las Redes Neuronales Profundas en su Detección Y Corrección*

Situación o error común	Impacto en la imagen diagnóstica	Intervención de redes neuronales profundas (ia)	Autores que respaldan
Movimiento del paciente (respiración, temblor, mala inmovilización)	Borrosidad, pérdida de nitidez, deformación de bordes	CNN detectan patrones de movimiento, clasifican artefactos y permiten corrección automática mediante redes de restauración	Ettehadí et al. (2022); Jimeno et al. (2025); Lim et al. (2022)
Errores en la técnica de adquisición (mala posición, ángulo incorrecto, tiempo de exposición inadecuado)	Doble contorno, distorsión geométrica, variación en densidad	Modelos de IA identifican desviaciones técnicas y alertan condiciones incorrectas antes de la adquisición definitiva	Azevedo-Marques & Carvalho (2021); Honey et al. (2017)
Artefactos metálicos por prótesis o implantes	Halos, líneas brillantes, sombras extensas	Redes profundas residuales reducen halos y reconstruyen regiones afectadas mediante aprendizaje basado en TAC sin artefactos	Huang et al. (2018); Kim et al. (2022)
Fallos del equipo (calibración deficiente, defectos en el detector, ruido electrónico)	Bandas, ruido excesivo, variación de uniformidad	Algoritmos ligeros de IA detectan patrones anormales en sensores y permiten generar mapas de calidad para mantenimiento predictivo	Gao et al. (2023); Hammerström et al. (2015)
Mantenimiento insuficiente del equipo	Mayor frecuencia de ruido, artefactos de procesado o calibración	IA puede anticipar fallos mediante análisis de series históricas de	Honey et al. (2017); ACR (2017)

Situación o error común	Impacto en la imagen diagnóstica	Intervención de redes neuronales profundas (ia)	Autores que respaldan
Errores de reconstrucción digital (rango dinámico, matrices incompletas)	Pérdida de contraste, ruido estructurado	imágenes, reduciendo artefactos recurrentes Redes neuronales optimizan el contraste y reducen ruido mediante aprendizaje supervisado en grandes bases de datos	Bansal (2006); González et al. (2022)
Errores humanos en la adquisición	Repetición de estudios, disminución de calidad	Sistemas IA integrados a PACS guían la adquisición y detectan imágenes no diagnósticas en tiempo real	Andriole et al. (2023); Lubinus Badillo & Rueda Hernández (2021)

*Fuente.* Elaboración propia (A. Arcila, 2025). El deep learning es una rama del aprendizaje automático que utiliza arquitecturas de redes neuronales con múltiples capas para procesar grandes volúmenes de datos y aprender patrones complejos. Las redes neuronales convolucionales (CNN) son un tipo de modelo de deep learning diseñado específicamente para analizar imágenes, ya que emplean filtros o convoluciones que permiten identificar características como bordes, formas, texturas y patrones asociados a artefactos en imágenes diagnósticas.

**Tabla 2***Comparativo Internacional*

Criterio	Colombia	España	Canadá	Alemania	Chile	Reino Unido	Estados Unidos	Japón
Nivel de adopción de IA en radiología	Emergente; avances académicos y pilotos clínicos.	Alta integración clínica; hospitales grandes usan IA rutinaria.	Muy avanzada; estrategia nacional estructurada.	Sofisticada; IA integrada en equipos de imagen.	Intermedia; depende de instituciones líderes.	Avanzada pero con adopción cautelosa; procesos revisados por NHS/NICE.	Muy rápida y amplia; fuerte industria tecnológica.	Avanzada, con IA incorporada directamente en equipos de diagnóstico.
Uso de IA para corrección/detección de artefactos	Limitado; predominan métodos manuales.	Corrección de artefactos metálicos y de movimiento en RM y TC.	Deep learning para movimiento en RM pediátrica, fallas de detectores y QA automático.	Modelos robustos que corrigen artefactos en tiempo real sin perder anatomía.	Interés creciente; uso puntual para mejorar calidad y priorización.	IA detecta imágenes borrosas o defectuosas antes de llegar al radiólogo.	Participa en competencias RSNA y equipos aprobados por FDA capaces de detectar artefactos automáticamente.	Corrección automática integrada en el equipo (RM y TC), enfoque industrial.
Infraestructura tecnológica	Heterogénea; muchos	Equipos modernos y PACS	Infraestructura uniforme y	Equipos de última generación	Infraestructura variable; centros	Buena infraestructura	Alta tecnología en centros grandes;	Industria avanzada que incorpora IA

Criterio	Colombia	España	Canadá	Alemania	Chile	Reino Unido	Estados Unidos	Japón
	equipos antiguos.	integrados.	digitalizada.	con IA nativa.	universitarios están más avanzados.	hospitalaria digital.	brechas en centros pequeños.	en el hardware.
Formación del tecnólogo / personal en IA	En desarrollo; poca oferta formal.	Formación activa promovida por SERAM.	Capacitación continua estandarizada.	Alta especialización para manejo de IA.	En crecimiento; iniciativas de sociedades científicas.	Formación regulada por NHS; enfoque en calidad y seguridad.	Amplia oferta académica; formación variada por institución.	Formación basada en industria; entrenamiento especializado por fabricantes.
Marco regulatorio en IA médica	INVIMA sin guías específicas para IA.	Regulado por normativas europeas y guías SERAM.	Guías CAR sobre ética, validación y privacidad.	AI Act europeo + certificaciones técnicas estrictas.	Regulación más clara para Software como Dispositivo Médico (SaMD).	Evaluación estricta por NICE y NHSX.	FDA regula dispositivos de IA; procesos de aprobación estructurados.	Regulación basada en estándares industriales y seguridad del paciente.
Integración al flujo de trabajo clínico	Baja; IA usada fuera de rutina.	Sistemas automáticos chequean calidad antes del PACS.	Integración regional (Ontario Health, hospitales universitarios).	Flujo totalmente integrado desde adquisición hasta	Integración limitada; depende de cada institución.	IA revisa calidad antes del radiólogo para optimizar flujo.	IA integrada en PACS, flujos y plataformas nacionales (RSNA).	IA embebida en equipos evita instalación externa.

Criterio	Colombia	España	Canadá	Alemania	Chile	Reino Unido	Estados Unidos	Japón
Fortalezas	Interés académico; investigaciones emergentes.	Personal capacidad; protocolos claros; buena integración.	Marco regulatorio sólido y validación multicéntrica.	reconstrucción. Industria + investigación + regulación → sistema altamente confiable.	Avances en regulación SaMD; interés regional.	Procesos rigurosos garantizan seguridad y eficacia.	Innovación acelerada; apoyo de industria y FDA.	IA integrada desde el hardware facilita adopción.
Limitaciones	Ausencia de lineamientos claros; infraestructura desigual.	Requiere inversión continua.	Costos altos y requisitos de validación compleja.	Alto costo tecnológico; limitado acceso global.	Adopción desigual; falta de infraestructura homogénea.	Adopción más lenta por procesos estrictos.	Desigualdad entre centros avanzados y rurales.	Tecnologías costosas de difícil acceso para países en desarrollo.
Perspectivas de evolución	Gran potencial si se fortalecen regulación y capacitación.	Mayor optimización de dosis y calidad en TC y RM.	Continuará estableciendo estándares globales.	Tendencia hacia sistemas autónomos de control de calidad.	Expansión si se fortalece infraestructura y formación.	Mayor integración segura y basada en evidencia.	Más dispositivos IA aprobados y adopción masiva.	Integración total de IA en adquisición y procesamiento.

*Nota.* La información de la tabla es una recopilación del estado del arte en diferentes países.



## Conclusiones

El análisis realizado demuestra que la presencia de artefactos en las imágenes diagnósticas no solo afecta la calidad técnica del estudio, sino que también influye de forma directa en la experiencia del paciente. Cuando una imagen no es diagnóstica y debe repetirse, el usuario enfrenta tiempos de espera prolongados, incomodidad física, aumento de la ansiedad y, en algunas modalidades como la tomografía, una exposición adicional que podría haberse evitado. Esto evidencia que la calidad de adquisición es un componente esencial tanto para la precisión clínica como para el bienestar del paciente.

La revisión de literatura muestra que las redes neuronales profundas ofrecen soluciones capaces de anticipar y corregir los errores más frecuentes, logrando imágenes más limpias y reduciendo la necesidad de repetir estudios. Estas herramientas pueden identificar patrones de movimiento, ruido o distorsión con mayor rapidez que el ojo humano, permitiendo que el estudio se complete adecuadamente en un solo intento. Como resultado, el proceso se vuelve más ágil y predecible, disminuyendo la molestia del paciente y mejorando su percepción del servicio.

Al asegurar imágenes de mejor calidad desde el primer momento, la atención se vuelve más segura y eficiente. El paciente pasa menos tiempo en el equipo, experimenta menos interrupciones y recibe un estudio confiable sin exposiciones adicionales. Esto transforma su vivencia del procedimiento, haciéndolo menos estresante y más orientado al cuidado integral.

La incorporación de estas tecnologías también fortalece el rol del Tecnólogo en Imágenes Diagnósticas. Al reducir la carga operativa asociada a repeticiones y verificaciones manuales, el profesional puede dedicar más atención al acompañamiento, la preparación del paciente y la comunicación, elementos que influyen de manera decisiva en una experiencia más humanizada.

La combinación entre la capacidad técnica de la IA y la interacción humana del tecnólogo genera un entorno donde la precisión diagnóstica y el confort del paciente avanzan simultáneamente.

En conjunto, los avances en redes neuronales profundas permiten afirmar que la mejora de la calidad de imagen no es solo un beneficio tecnológico, sino una herramienta con impacto directo en la seguridad, comodidad y tranquilidad del paciente. Su integración en los servicios de radiología representa un paso importante hacia prácticas más eficientes, humanas y centradas en las necesidades reales de quienes acuden a un estudio diagnóstico.

### Referencias bibliográficas

- American College of Radiology. (2017). *ACR–AAPM Technical Standard for Diagnostic Medical Physics Performance Monitoring of Radiographic Equipment*. ACR.  
<https://www.acr.org/>
- Azevedo-Marques, P. M., & Carvalho, C. R. (2021). *Quality control in diagnostic radiology: Challenges in digital imaging*. *Radiologia Brasileira*, 54(1), 1–6.  
<https://doi.org/10.1590/0100-3984.2020.54.1e1>
- Bansal, G. J. (2006). *Digital radiography: A comparison with modern imaging techniques*. *Postgraduate Medical Journal*, 82(969), 425–428.  
<https://doi.org/10.1136/pgmj.2005.040972>
- Carrizales, J. W., Flakus, M. J., Fairbourn, D., Shao, W., Gerard, S. E., Bayouth, J. E., Christensen, G. E., & Reinhardt, J. M. (2025). *4DCT image artifact detection using deep learning*. PubMed. <https://pubmed.ncbi.nlm.nih.gov/39540716>
- Chacón Jiménez, M. (2025). *Avances de la inteligencia artificial en radiología*. Revista Electrónica de PortalesMedicos.com. <https://www.portalesmedicos.com/>
- Jia, H., Zhang, J., Ma, K., Qiao, X., Ren, L., & Shi, X. (2022). *Aplicación de redes neuronales convolucionales en el análisis de imágenes médicas: retos y perspectivas*. Redalyc.  
<https://pmc.ncbi.nlm.nih.gov/articles/PMC11074758/>
- Hammerström, C. (2015). *Quality control in computed radiography systems*. *Journal of Radiology*, 87(5), 102–109.
- Honey, I. (2017). *Quality assurance in digital radiology: Guidelines and recommendations*. *Radiology Practice*, 56(3), 221–229.

- Huang, X., Wang, J., Tang, F., & Zhong, T. (2018). *Metal artifact reduction on cervical CT images by deep residual learning*. *BioMedical Engineering Online*, 17, 33.  
<https://doi.org/10.1186/s12938-018-0456-4>
- International Atomic Energy Agency. (2018). *Quality assurance programme for digital radiography*. IAEA. <https://www.iaea.org/>
- Manso Jimeno, M., Ravi, K. S., Fung, M., Oyekunle, D., Ogbole, G., Vaughan, J. T., Jr., & Geethanath, S. (2025). *Automated detection of motion artifacts in brain MR images*. PubMed. <https://pubmed.ncbi.nlm.nih.gov/39439086>
- Lim, A., Lo, J., Wagner, M. W., Ertl-Wagner, B., & Sussman, D. (2022). *Automatic artifact detection algorithm in fetal MRI*. *Frontiers in Artificial Intelligence*, 5, 861791.  
<https://doi.org/10.3389/frai.2022.861791>
- Lubinus Badillo, F., & Rueda Hernández, C. A. (2021). *Redes neuronales convolucionales: Un modelo de Deep Learning en imágenes diagnósticas*. *Revista Colombiana de Radiología*, 32(1), 87–95. <https://doi.org/10.53903/01212095.16>
- Luini, L., Villarreal, E., & Villarreal, L. (2016). *Detección y diagnóstico de fallas mediante técnicas de inteligencia artificial: Un estado del arte*. *Revista Facultad Tecnológica*, Universidad Distrital.
- Mall, P. K., & Gupta, S. (2023). *Una revisión integral de redes neuronales profundas para el análisis de imágenes médicas*. *Biocybernetics and Biomedical Engineering*, 43(3), 713-729. <https://www.sciencedirect.com/science/article/pii/S2772442523000837>
- Méndez Gómez, A. Y. (2025). *Reconstrucción inteligente en TC: Utilidad de las redes neuronales convolucionales (CNN) en la detección y corrección de artefactos*.

Universidad Nacional Abierta y a Distancia.

<https://repository.unad.edu.co/handle/10596/68314>

Mienye, I. D. (2025). *Redes neuronales convolucionales profundas en el análisis de imágenes médicas*. *Information*, 16(3), 195. <https://www.mdpi.com/2078-2489/16/3/195>

Obuchowicz, R., Lasek, J., Wodziński, M., Piórkowski, A., Strzelecki, M., & Nurzynska, K. (2025). *Radiología potenciada por inteligencia artificial: aplicaciones actuales y perspectivas futuras*. *Diagnostics*, 15(4), 678.

<https://pubmed.ncbi.nlm.nih.gov/articles/PMC11816879>

Peña, M. A., Mendez-Avila, C., Torre, S., Arce, V., Riquelme Contreras, P., Rios, J., Baldelmir Olmedo, N., Gonzalez, H., Cardona Hernandez, Y., Cabezas, A., Lucero, M., Ezquerro, V., Malamateniou, C., & Solís-Barquero, S. M. (2023). *Artificial intelligence in radiology: overview of the state of the art in Latin America*. ResearchGate.

<https://www.researchgate.net/publication/394401852>

Pivaral Guerra, H. A. (2024). *Generación de datos sintéticos con inteligencia artificial*. Universidad del Valle de Guatemala.

<https://repositorio.uvg.edu.gt/handle/123456789/5916>

Roecher, E., Mösch, L., Zweerings, J., Thiele, F. O., Caspers, S., Gaebler, A. J., Eisner, P., Sarkheil, P., & Mathiak, K. (2024). *Motion artifact detection for T1-weighted brain MR images*. PubMed. <https://pubmed.ncbi.nlm.nih.gov/38989919>

Sartori, P. (2015). *Artefactos y artificios frecuentes en tomografía computada y resonancia magnética*. *Revista Argentina de Radiología*, 79(3), 197–206. <https://www.elsevier.es/es-revista-revista-argentina-radiologia-383>

- Seeram, E. (2008). *Image postprocessing in digital radiology: A primer for radiologists*. *Journal of Medical Imaging and Radiation Sciences*, 39(2), 75–83.  
<https://doi.org/10.1016/j.jmir.2008.01.001>
- Seibert, J. A. (2006). *Digital radiography: The bottom line comparison of CR and DR technology*. *Journal of Digital Imaging*, 19(Suppl 1), 3–10.  
<https://doi.org/10.1007/s10278-006-0863-8>
- Singh, R., Singh, N., & Kaur, L. (2025). *Deep learning methods for 3D magnetic resonance image denoising and artifact removal*. PubMed.  
<https://pubmed.ncbi.nlm.nih.gov/39569887>
- Zhang, Y., & Yu, H. (2017). *Convolutional neural network based metal artifact reduction in X-ray computed tomography*. *IEEE Transactions on Medical Imaging*, 37(6), 1370–1381.  
<https://doi.org/10.1109/TMI.2017.2764486>
- Arabi, H., & Zaidi, H. (2021). *Deep learning-based metal artefact reduction in PET/CT imaging*. *European Radiology*, 31(8), 6384–6396. <https://pubmed.ncbi.nlm.nih.gov/33569626/>
- Cui, L., Song, Y., Wang, Y., Wang, R., Wu, D., Xie, H., ... & Yang, G. (2023). *Motion artifact reduction for magnetic resonance imaging with deep learning and k-space analysis*. *PLOS ONE*, 18(1), e0278668.  
<https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0278668>
- Jiang, S., Sun, Y., Xu, S., Zhang, Z., & Wu, Z. (2024). *Metal Artifact Correction in Industrial CT Images Based on a Dual-Domain Joint Deep Learning Framework*. *Applied Sciences*, 14(8), 3261. <https://www.mdpi.com/2076-3417/14/8/3261>

Zou, H., et al. (2025). Metal-artifact reduction combined with deep-learning image reconstruction improves CT image quality at high kVp. *PeerJ*.

<https://peerj.com/articles/19516.pdf>