

**Redes neuronales convolucionales en la mejora de la calidad de imagen en tomografía
computarizada: modelos U-Net y GAN aplicados a la reconstrucción y reducción de
artefactos**

Maibe Yurraime Botia Duran

Brayan Darío Flórez Sierra

Claudia Karina Mogollón Gamboa

Dolly Mariana Parra Melo

Oscar Azael Walteros Pérez

Asesor

Javier Alberto Perez Murillas

Universidad Nacional Abierta y a Distancia - UNAD

Escuela de Ciencias de la Salud ECISA

Tecnología en Radiología e Imágenes Diagnósticas

2025

Agradecimientos

El presente trabajo es el resultado de la constancia, el compromiso y el esfuerzo compartido de muchas personas que acompañaron este proceso académico y personal.

En primer lugar, agradecemos a Dios, fuente de fortaleza y sabiduría, por guiarnos en cada etapa del camino, dándonos claridad ante las dificultades y motivación para seguir avanzando con esperanza.

A nuestras familias, por su apoyo incondicional, paciencia y comprensión en los momentos de mayor exigencia. Su amor y confianza fueron el impulso que nos permitió mantenernos firmes hasta alcanzar esta meta.

Agradecemos también a nuestro asesor, Javier Alberto Pérez Murillas, A nuestra estimada directora Edna Rocío Jamaica Guio, por su orientación, compromiso y disposición constante para acompañarnos en el desarrollo de esta investigación, aportando sus conocimientos y experiencias que enriquecieron de manera significativa nuestro aprendizaje.

Reconocemos igualmente el apoyo de nuestros compañeros de programa, con quienes compartimos experiencias, retos y aprendizajes que fortalecieron nuestras competencias académicas y humanas. Su colaboración y espíritu de equipo hicieron de este recorrido una etapa de crecimiento conjunto.

Finalmente, expresamos nuestro sincero agradecimiento a la Universidad Nacional Abierta y a Distancia (UNAD) por brindarnos un espacio educativo que promueve la formación integral, la investigación y el desarrollo profesional con sentido humano y social.

Resumen

La presente investigación analiza el uso de redes neuronales convolucionales (CNN), en particular los modelos U-Net y GAN, en la reducción de artefactos y mejora de la calidad de imagen en tomografía computarizada (TC). Este surge ante la limitación diagnóstica provocada por artefactos generados por objetos metálicos, movimientos del paciente y deficiencias en los algoritmos de reconstrucción. Se adopta un enfoque cualitativo basado en una revisión narrativa de literatura científica publicada entre 2014 y 2025, seleccionada en bases de datos reconocidas y analizada mediante tablas comparativas.

Los resultados evidencian que las CNN superan los métodos tradicionales al mejorar la fidelidad anatómica y reducir el ruido. Los modelos U-Net destacan por conservar detalles estructurales, mientras que las GAN generan reconstrucciones más realistas al aplicar estrategias de atención guiada. Sin embargo, persisten limitaciones como la falta de estandarización, el acceso restringido a bases de datos clínicas y la necesidad de validación multicéntrica. En conclusión, las CNN constituyen una herramienta prometedora para optimizar la calidad diagnóstica y la seguridad del paciente en TC, siempre que su implementación respete criterios éticos y técnicos.

Palabras clave: Tomografía, Inteligencia Artificial, Redes Neuronales, Artefactos, Aprendizaje

Abstract

This research analyzes the use of convolutional neural networks (CNNs), particularly the U-Net and GAN models, in the reduction of artifacts and enhancement of image quality in computed tomography (CT). The study arises from diagnostic limitations caused by artifacts generated by metallic objects, patient motion, and deficiencies in conventional reconstruction algorithms. A qualitative approach was adopted, based on a narrative review of scientific literature published between 2014 and 2025, selected from recognized databases and analyzed through comparative tables.

The results show that CNNs outperform traditional methods by improving anatomical fidelity and reducing image noise. The U-Net model effectively preserves structural details, while GANs produce more realistic reconstructions through guided attention strategies. However, challenges remain, such as the lack of standardization, limited access to clinical databases, and the need for multicenter validation.

In conclusion, CNNs represent a promising tool to optimize diagnostic quality and patient safety in CT imaging, provided that their implementation adheres to ethical and technical standards.

Keywords: Tomography, Artificial Intelligence, Convolutional Networks, Artifacts, Learning.

Tabla de Contenido

Introducción	9
Planteamiento del problema	10
Justificación.....	11
Objetivos	12
Objetivo General	12
Objetivos Específicos.....	12
Marco Teorico.....	13
Formación De La Imagen	13
Factores Que Afectan La Calidad De La Imagen	16
<i>Parámetros De Adquisición</i>	<i>16</i>
<i>Características Del Paciente</i>	<i>16</i>
<i>Artefactos</i>	<i>16</i>
Endurecimiento Del Haz.....	17
Cuerpos Extraños Metálicos.....	18
Proyección Incompleta.....	19
<i>Algoritmos De Reconstrucción.....</i>	<i>19</i>
Procesos De Reconstrucción De La Imagen.....	19
Reconstrucción De La Imagen En Tomografía Computarizada	20
Redes Neuronales Convolucionales (CNN).....	20
<i>Principios De Funcionamiento</i>	<i>21</i>
<i>Fundamento Y Dominios De Aplicación.....</i>	<i>21</i>
<i>Arquitecturas Y Diseño Funcional.....</i>	<i>24</i>

<i>Estrategias De Datos Y Entrenamiento</i>	26
<i>Funciones De Pérdida Y Evaluación</i>	27
Marco Conceptual	29
Marco Normativo	30
Proyecto de Ley sobre Inteligencia Artificial en Colombia.....	30
Normativas Internacionales En IA Aplicada A La Salud	32
Marco Metodológico	33
Fase I. Contextualización Del Problema De Investigación.....	33
Fase II. Análisis Y Construcción Del Marco Teórico.....	33
Fase III. Aplicación Metodológica Y Formulación De Objetivos	34
Fase IV. Consolidación De Resultados Y Elaboración Del Informe Final.....	35
Revisión Documental Y Análisis De Fuentes Científicas	35
<i>Criterios De Inclusión</i>	36
<i>Criterios De Exclusión</i>	36
Análisis Y Resultados De La Literatura Revisada	41
<i>Comparación de Resultados en Reducción de Artefactos y Optimización de Imagen en TC</i> <i>Mediante IA de Literatura Revisada.</i>	44
Discusión.....	46
Conclusiones	51
Referencias Bibliográficas.....	52

Lista de Figuras

Figura 1 <i>Unidades Hounsfield O Número TC</i>	14
Figura 2 <i>Tonalidades de Gris Según El Número de Bits de un Píxel</i>	15
Figura 3 <i>Matrix, Píxel Y Vóxel</i>	15
Figura 4 <i>Artefacto por Movimiento en Imagen de TC</i>	16
Figura 5 <i>Artefacto por Endurecimiento del Haz</i>	17
Figura 6 <i>Artefacto por Cuerpos Extraños Metálicos</i>	17
Figura 7 <i>Artefacto por Entrada de Flujo</i>	18
Figura 8 <i>Artefacto por Proyección Incompleta</i>	18
Figura 9 <i>Reconstrucción Policromática Convencional Axial con y Sin o-MAR</i>	22
Figura 10 <i>Comparación entre Imágenes Convencionales y Reconstrucciones con MAR</i>	23
Figura 11 <i>Esquema Arquitectura CALIMAR-GAN</i>	25
Figura 12 <i>Construcción del Conjunto de Datos Mediante Máscaras Metálicas</i>	26
Figura 13 <i>Ejemplos de Máscaras Binarias Empleadas en el Conjunto de Datos</i>	28

Lista De Tablas

Tabla 1 <i>Términos y Definiciones Sobre CNN y Reducción de Artefactos Metálicos en TC....</i>	29
Tabla 2 <i>Síntesis de las Fases Metodológicas del Estudio.....</i>	35
Tabla 3 <i>Clasificación de la Literatura Revisada Sobre Artefactos En TC</i>	37
Tabla 4 <i>Clasificación de Literatura Sobre IA Y CNN en la Reconstrucción O Mejora de TC....</i>	38
Tabla 5 <i>Análisis de Fuentes Utilizadas para la Fundamentación Conceptual.....</i>	39
Tabla 6 <i>Análisis de Estudios Sobre el Uso de IA y CNN.....</i>	40
Tabla 7 <i>Comparación de Resultados en Reducción de Artefactos Mediante IA.....</i>	44
Tabla 8 <i>Síntesis Analítica de la Discusión: Resultados y Desafíos</i>	46

Introducción

La tomografía computarizada (TC) ha transformado la práctica radiológica al ofrecer imágenes anatómicas de alta resolución que permiten diagnósticos más precisos y tratamientos mejor dirigidos. Su importancia en la medicina ha impulsado la búsqueda constante de herramientas que optimicen la calidad de imagen y fortalezcan la seguridad del paciente. En este escenario, la inteligencia artificial (IA) se ha consolidado como un recurso innovador capaz de mejorar los procesos de reconstrucción y análisis de imágenes médicas, introduciendo nuevas posibilidades en la gestión y procesamiento de datos complejos.

Entre las múltiples aplicaciones de la IA, el uso de redes neuronales convolucionales (CNN) ha cobrado especial relevancia en el campo de la radiología. En particular, los modelos U-Net y GAN (Generative Adversarial Networks) se destacan por su capacidad de aprender patrones de imagen y generar reconstrucciones más precisas y visualmente coherentes. Estos avances tecnológicos han abierto nuevas perspectivas para la optimización del diagnóstico por imágenes, al tiempo que plantean desafíos éticos, metodológicos y de validación clínica que demandan análisis crítico y reflexión profesional.

En este contexto, el trabajo que se presenta a continuación tiene como propósito aportar a la comprensión teórica y práctica del papel de las redes neuronales profundas en la reconstrucción de imágenes médicas, promoviendo un equilibrio entre el avance científico, la validación clínica y el compromiso ético del profesional en radiología.

Planteamiento del Problema

La tomografía computarizada (TC) es una de las herramientas más importantes en la práctica clínica, por su capacidad de proporcionar imágenes detalladas del cuerpo humano. Aún así, su eficacia diagnóstica se ve limitada por la presencia de artefactos, especialmente los asociados a objetos metálicos, movimientos del paciente y deficiencias en la reconstrucción de la imagen, lo cual repercute directamente en la calidad de las imágenes y en su seguridad. Estos inconvenientes no solo dificultan la interpretación clínica, sino que también pueden aumentar la frecuencia de repetir estudios, generando una mayor exposición a la radiación y costos adicionales para el sistema de salud (Sánchez & Gómez, 2025).

Ante esta problemática, las redes neuronales convolucionales (CNN) se han consolidado como una herramienta innovadora para la reducción de artefactos en la optimización de la calidad de imagen en TC. Sin embargo, su implementación aún enfrenta importantes dificultades técnicas, como el riesgo de sobreajuste, la pérdida de detalles anatómicos relevantes, así como la escasa interpretabilidad de los resultados. A ello se suman limitaciones como la escasez de bases de datos clínicas representativas, la falta de estandarización entre equipos y protocolos, y las restricciones éticas y legales en el uso de la información y la ausencia de una validación clínica multicéntrica. Todo esto ha generado desconfianza y retraso en la adopción de tales innovaciones en la práctica médica (Zhu et al., 2023; Xu et al., 2024). En este contexto, surge la pregunta de investigación: ¿Cómo pueden los algoritmos de inteligencia artificial, en particular las redes neuronales convolucionales, contribuir a reducir los artefactos y optimizar la calidad de las imágenes en tomografía computarizada? Dar respuesta a este interrogante permitirá orientar el análisis crítico y valorar el potencial de estas herramientas en la práctica clínica.

Justificación

La importancia de esta investigación se fundamenta en la necesidad de analizar cómo los algoritmos de inteligencia artificial pueden contribuir a la optimización de las imágenes en tomografía computarizada, un campo en el que persisten limitaciones técnicas y metodológicas relevantes. En este sentido, explorar el potencial de los algoritmos de inteligencia artificial para la optimización de imágenes no solo favorece la precisión diagnóstica, sino que también abre la posibilidad de estandarizar procedimientos y reducir la variabilidad entre equipos y protocolos (Sánchez & Gómez, 2025).

Frente a este panorama, surge la necesidad de realizar un análisis sistemático y crítico sobre el estado actual de la literatura científica relacionada con el uso de CNN en la reducción de artefactos en TC. Este análisis, de carácter cualitativo y basado en una revisión narrativa de estudios previos, permitirá identificar tanto los avances alcanzados como las limitaciones y vacíos de conocimiento que aún persisten en este campo.

De esta manera, el aporte de este estudio se orienta a consolidar el conocimiento existente mediante el análisis de la literatura especializada, sentando bases conceptuales para futuras investigaciones y favoreciendo la comprensión integral de los retos y oportunidades en la implementación de estas tecnologías en radiología. Así, se busca contribuir al fortalecimiento del ejercicio académico y profesional de radiólogos, tecnólogos en imágenes diagnósticas e investigadores interesados en el desarrollo de soluciones innovadoras para mejorar la calidad de las imágenes médicas.

Objetivos

Objetivo General

Analizar el uso de redes neuronales convolucionales, particularmente los modelos U-Net y GAN, en la reducción de artefactos y la mejora de la calidad de imagen en tomografía computarizada, a partir de una revisión crítica de la literatura científica reciente.

Objetivos Específicos

Identificar los principales tipos de artefactos presentes en los estudios de tomografía computarizada y su efecto en la calidad diagnóstica.

Describir los fundamentos teóricos y arquitectónicos de las redes neuronales convolucionales aplicadas a la reconstrucción de imágenes médicas.

Comparar las características metodológicas, resultados y limitaciones reportadas en la literatura científica sobre los modelos U-Net y GAN para la reducción de artefactos.

Analizar la evidencia científica recopilada para determinar las ventajas, limitaciones y proyecciones futuras del uso de redes neuronales convolucionales en la práctica radiológica

Marco Teórico

En el ámbito de la radiología e imágenes diagnósticas, la TC ha evolucionado gracias a la incorporación de detectores más sensibles, velocidades de adquisición y algoritmos de reconstrucción avanzados. Estos progresos han permitido obtener cortes de alta resolución que favorecen la detección y caracterización de patologías con gran precisión. Sin embargo, a pesar de estas mejoras, la calidad de la imagen continúa condicionada por la aparición de artefactos que pueden alterar la interpretación clínica.

La presencia de artefactos no solo compromete la interpretación diagnóstica, sino que también incrementa la probabilidad de falsos positivos o negativos, lo que puede retrasar decisiones clínicas oportunas y afectar la seguridad del paciente. Además, su impacto se extiende más allá del ámbito clínico, generando ineficiencias en los procesos hospitalarios. De acuerdo con Scardigno et al. (2025), En los últimos años, la investigación sobre reducción de artefactos se ha intensificado debido a la creciente demanda de imágenes de mayor fidelidad. Este interés ha impulsado la búsqueda de métodos innovadores que superen las limitaciones de los algoritmos convencionales.

Formación De La Imagen

La formación de la imagen en TC se fundamenta en la atenuación diferencial de los rayos X al atravesar el cuerpo del paciente. Cada tejido absorbe la radiación en función de su densidad y número atómico, generando diferencias en la intensidad que alcanza los detectores. Estas diferencias se cuantifican mediante los coeficientes de atenuación lineal (μ), que constituyen la base matemática para la creación de las imágenes (Costa & Soria, 2015).


En la práctica, el tubo de rayos X emite un haz en forma de abanico (en generaciones iniciales) o en cono (en generaciones más modernas), que recorre el área de interés en múltiples

ángulos gracias al movimiento rotacional del gantry. Los detectores transforman la radiación en señales eléctricas, que son digitalizadas y almacenadas como datos de proyección. Estos datos representan la cantidad de radiación atenuada por cada trayectoria a través del cuerpo y constituyen las llamadas proyecciones radiales.

Para facilitar la interpretación clínica, los valores de atenuación se convierten en unidades Hounsfield (UH), estableciendo como referencia el agua con un valor de 0 UH, el aire con -1000 UH y los huesos compactos con valores que superan $+1000$ UH. Este sistema de referencia estandariza la visualización y comparación de imágenes, como se observa a continuación.

Figura 1

Unidades Housfield o Número TC. (Imagen cortesía de Siemens.)











Nota. Costa, J; Soria, A. 2015

La imagen digital se compone de una matriz, formada por celdas organizadas en filas y columnas. En la figura 3, se puede apreciar que cada celda corresponde a un píxel (elemento de imagen), al cual se le asigna un valor de atenuación expresado en UH. Este valor se visualiza en escala de grises, donde los tonos más oscuros representan baja densidad (ej. aire) y los más claros, alta densidad (ej. hueso), (Véase figura 2). Al considerar además el grosor de corte, se incorpora la tercera dimensión, constituyendo los vóxeles, que son las unidades de volumen mínimas representadas en la imagen tomográfica.

Figura 2

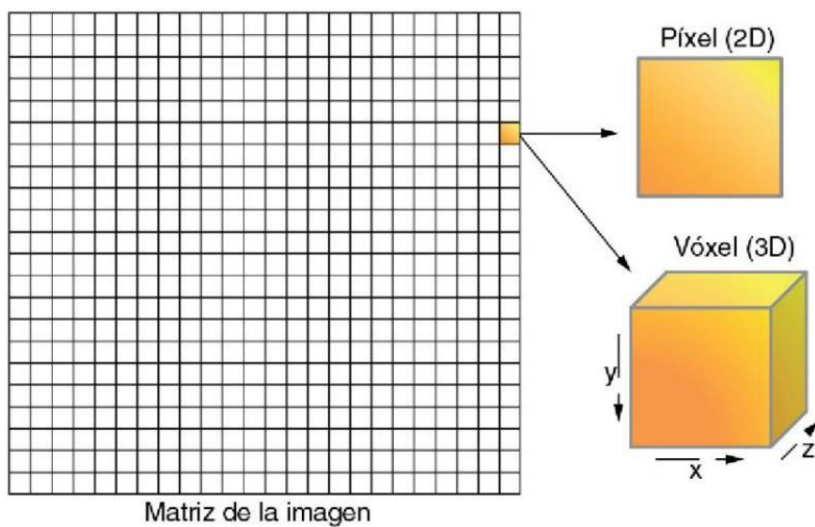
Tonalidades De Gris Según El Número De Bit De Un Píxel

Bit × píxel	Número de tonalidades	Escala de gris
1	2	
2	4	
3	8	
4	16	
5	32	
6	64	
7	128	
8	256	

Nota. Costa, J; Soria, A. 2015

Figura 3

Matrix, Pixel Y Voxel.



Nota. Costa, J; Soria, A. 2015

Factores que Afectan la Calidad de la Imagen

La calidad de las imágenes obtenidas en TC depende de múltiples variables técnicas y fisiológicas que, en conjunto, determinan la precisión diagnóstica, Costa y Soria (2015) destacan que entre los principales factores se encuentran:

Parámetros de Adquisición

El voltaje del tubo, la corriente, el tiempo de exposición y el grosor de corte influyen directamente en la resolución y en el contraste de la imagen.

Características del Paciente

La complejión, la movilidad y la presencia de objetos metálicos implantados pueden generar atenuaciones heterogéneas que dificultan la interpretación.


Artefactos

Distorsiones derivadas de factores físicos, del movimiento del paciente o de materiales de alta densidad, que reducen la nitidez y pueden inducir errores diagnóstico.

Movimiento del Paciente. Se produce por respiración, latidos, temblores o falta de colaboración. Se manifiesta como imágenes fantasmales, contornos duplicados o distorsión anatómica. Se reduce con una adecuada preparación del paciente, uso de técnicas rápidas (TC multicorte) o, en pediatría, con inmovilización o sedación, véase a continuación.

Figura 4

Artefacto por Movimiento en Imagen de TC



Nota. Sartori et al. 2015

Endurecimiento Del Haz. Ocurre cuando los tejidos absorben de forma desigual los fotones de baja energía, sobre todo en hueso, produciendo bandas claras y oscuras. Se corrige con filtros, aumento de kilovoltaje o técnicas de modulación de dosis. Véase figura 5

Figura 5

Artefacto por Endurecimiento del haz




Nota. Sartori et al. 2015

Cuerpos Extraños Metálicos. Prótesis, material quirúrgico, piercings o contrastes generan rayos en abanico (“rayos de sol”). Como se observa en la figura 6. Se mitiga con cambios en la angulación, reconstrucciones algorítmicas o acercando el objeto al centro del campo.

Figura 6

Artefacto por Cuerpos extraños metálicos




Nota. Sartori et al. 2015

Entrada De Flujo. En estudios con contraste endovenoso precoz, produce hiperdensidades que dificultan la interpretación vascular. Se evita retrasando unos segundos el inicio del escaneo. Véase figura 7

Figura 7

Artefacto por Entrada de Flujo




Nota. Sartori et al. 2015

Proyección Incompleta. Cuando parte del cuerpo queda fuera del campo, aparecen bandas espiculadas. (figura 8), Se previene adaptando el área de estudio y con reformateos digitales.

Figura 8

Artefacto por Proyección incompleta



Nota. Sartori et al. 2015

Algoritmos de Reconstrucción

La elección del método de reconstrucción influye en la fidelidad de los detalles anatómicos. las técnicas convencionales como la retroproyección filtrada tienden a generar mayor ruido, mientras que los algoritmos iterativos ofrecen mejoras, pero aún presentan limitaciones en la resolución de artefactos complejos (Yasui et al., 2023).

Procesos de Reconstrucción de la Imagen

La TC no genera la imagen de manera directa como en la radiografía convencional, sino que depende de un proceso de reconstrucción. Los datos crudos obtenidos por los detectores requieren ser procesados mediante algoritmos computacionales para transformarse en datos de imagen (image data), es decir, en los valores de píxel que conforman la representación final.

Entre los algoritmos más empleados destacan la retroproyección filtrada, que corrige la

distorsión de las proyecciones, y los métodos de interpolación, que favorecen la continuidad de la imagen y reducen artefactos. La calidad de la reconstrucción está condicionada por parámetros técnicos como el kilovoltaje (kV), el miliamperaje (mA), la colimación, el grosor de corte y el factor pitch, así como por el ruido electrónico inherente al sistema, que puede limitar la visualización de estructuras de bajo contraste

Reconstrucción de la Imagen en Tomografía Computarizada

La reconstrucción es el proceso mediante el cual los datos de proyección se transforman en cortes transversales del cuerpo. En las primeras aplicaciones se utilizó la retroproyección simple, que consistía en proyectar de nuevo los valores registrados sobre una matriz. Sin embargo, este método producía imágenes borrosas.

Posteriormente se desarrolló la retroproyección filtrada (FBP, Filtered Back Projection), donde a cada proyección se le aplica un filtro matemático antes de la retroproyección. Este procedimiento permite obtener imágenes más nítidas y con mejor resolución espacial, siendo durante décadas el método estándar en TC (Costa & Soria, 2015).

Con la evolución tecnológica surgieron los algoritmos de reconstrucción iterativa (IR). Estos comparan de manera sucesiva los datos adquiridos con un modelo simulado de la imagen, corrigiendo errores y reduciendo el ruido de manera progresiva. La reconstrucción iterativa permite mejorar la calidad de imagen en estudios de baja dosis y ha abierto el camino a métodos más avanzados como los basados en inteligencia artificial.

Redes Neuronales Convolucionales (CNN)

Las CNN son arquitecturas de aprendizaje profundo diseñadas para procesar datos con estructura espacial. Su principal rasgo distintivo es la convolución: filtros (kernels) entrenables que extraen características locales (bordes, texturas, patrones) y que, aplicados en múltiples

capas, permiten aprender representaciones jerárquicas desde rasgos elementales hasta estructuras anatómicas complejas. Esta capacidad de aprender directamente desde los datos convierte a las CNN en herramientas idóneas para tareas de mejora de imagen y para realizar transformaciones de imagen a imagen (Scardigno et al., 2025). En el ámbito de la TC, las CNN se han propuesto como herramienta para mitigar artefactos que degradan la calidad diagnóstica y pueden afectar procesos subsecuentes como la cuantificación en PET/CT. Estas técnicas abordan el problema tanto desde la perspectiva de la apariencia visual como desde la necesidad de preservar la fidelidad cuantitativa de la imagen.

Principios ee Funcionamiento

Las CNN se componen de varias capas:

Capas convolucionales, que aplican filtros (kernels) para extraer características locales de la imagen (bordes, texturas, intensidades).

Capas de activación, que introducen no linealidad para mejorar la capacidad de aprendizaje.

Capas de agrupamiento (pooling), que reducen la dimensionalidad preservando la información relevante.

Capas totalmente conectadas, que integran las características obtenidas para generar la salida final.

Este proceso permite que las CNN transformen imágenes degradadas por artefactos en representaciones corregidas y con mejor calidad diagnóstica.

Fundamento y Dominios de Aplicación

Conceptualmente, las soluciones basadas en CNN para reducción de artefactos se implementan en tres dominios principales:

Modelos Imagen a Imagen. Estos modelos son los más directos ya que recibe como entrada una imagen de TC ya reconstruida pero afectada por artefactos metálicos (véase figura 9). Mediante su entrenamiento, la red aprende a generar como salida una imagen corregida, intentando preservar la anatomía real y eliminar las distorsiones, para entrenar este tipo de redes, se recurre a datos simulados: se parte de una imagen sin implantes y luego se le añade un implante virtual junto con el artefacto. De esta manera, la red tiene un “par” de referencia:


Entrada: imagen con artefacto simulado.

Salida deseada: la misma imagen sin artefacto.

como se puede observar en la figura 10

Figura 9

Reconstrucción Policromática Convencional Axial Con Y Sin O-MAR



Nota. Selles et al. 2024.

La CNN, a través de sus capas convolucionales, aprende las diferencias estadísticas y estructurales entre lo que es un artefacto y lo que corresponde a tejido real. Su ventaja es la simplicidad, ya que trabaja únicamente en el dominio de la imagen. Sin embargo, el inconveniente es que los artefactos ya están “propagados” en la reconstrucción, lo que limita la capacidad de eliminarlos por completo.

Modelos Sinograma a Sinograma. En este enfoque, la CNN no trabaja sobre la imagen reconstruida, sino sobre el sinograma, es decir, los datos de proyección que se obtienen directamente del escáner antes de la reconstrucción afectadas por metal y limitan la intervención en zonas sanas. Véase figura 10.

En el sinograma, los artefactos aparecen como regiones con información faltante o distorsionada debido a la atenuación extrema del metal. La CNN aprende a interpolar y corregir esas áreas defectuosas en el dominio de proyección, generando un sinograma más limpio, luego, ese sinograma corregido se utiliza para reconstruir la imagen final de TC.

La principal ventaja de este método es que los artefactos no llegan a propagarse a la imagen porque se corrigen en su origen. Además, permite preservar mejor la fidelidad de las estructuras anatómicas. Su limitación es que requiere acceso al sinograma y que el proceso de entrenamiento es más complejo, porque implica manejar datos crudos del escáner .

Modelos de Dominio Dual. Estos modelos son una evolución de los anteriores y se consideran los más robustos. la CNN recibe dos entradas simultáneas:


El sinograma afectado por artefactos, Del sinograma obtiene la información más “pura” antes de que los artefactos se propaguen.

La imagen reconstruida con esos mismos artefactos, de la imagen reconstruida aprovecha la organización espacial y anatómica de los tejidos.

El modelo combina ambas fuentes para producir imágenes corregidas con mayor fidelidad anatómica y menor distorsión, esta estrategia logra resultados superiores frente a los enfoques que usan únicamente la imagen o únicamente el sinograma, ya que la red dispone de más contexto para diferenciar entre tejido real y artefacto. Véase figura 10.

Figura 10

Comparación Imágenes Convencionales, O-MAR, Monoenergéticas y una Reconstrucción con MAR Basado en Deep Learning.



Nota. Selles et al. 2024.

Arquitecturas y Diseño Funcional

Las arquitecturas más empleadas en MAR (metal artifact reduction) incluyen U-Net y variantes encoder–decoder con *skip connections*, bloques residuales y, en problemas donde se prioriza realismo perceptual, esquemas adversariales (GAN).

Algunos algoritmos añaden entradas adicionales, como imágenes corregidas con técnicas clásicas por ejemplo, NMAR, lo que fortalece el aprendizaje .

Aprendizaje Supervisado y no Supervisado

Supervisado. requiere imágenes emparejadas con y sin artefacto. Esta estrategia mostró reducciones de artefactos más efectivas en comparación con métodos tradicionales como NMAR o interpolación lineal .

No supervisado. se basa en redes generativas adversarias (GANs), que no requieren pares de imágenes, eliminando la necesidad de simulaciones complejas. Estas técnicas han demostrado igualmente resultados prometedores .

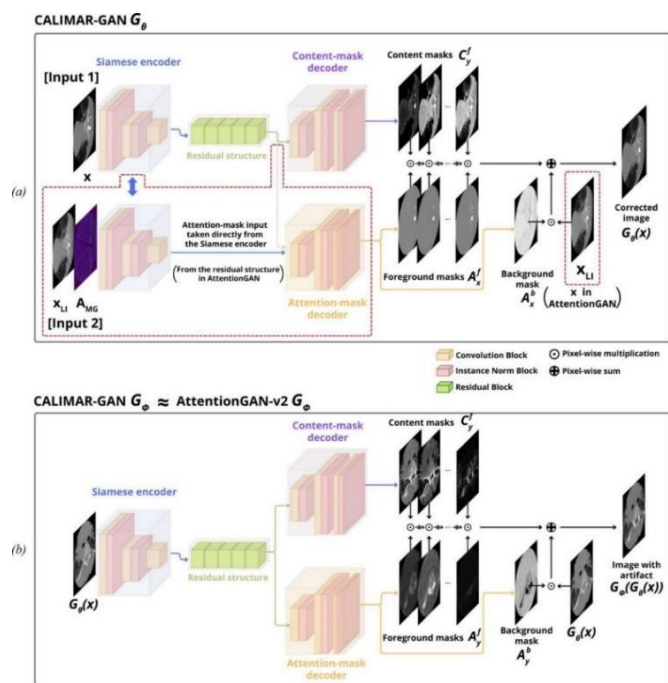
El modelo U-Net facilita la preservación de detalles locales mediante conexiones directas entre niveles de codificación y decodificación; los bloques residuales permiten que la corrección se aprenda como un término residual, acelerando la convergencia y reduciendo la degradación durante el entrenamiento. En escenarios con ausencia de pares de entrenamiento emparejados, las arquitecturas *cycle-consistent GAN* (CycleGAN) permiten aprender mapeos entre distribuciones sin correspondencia directa, incorporando términos de consistencia de ciclo e identidad para restringir transformaciones no deseadas.

Una contribución metodológica destacada es la incorporación de módulos de atención guiada por máscara que focalizan la corrección en las regiones afectadas por metal y limitan la intervención en zonas sanas. En el caso de CALIMAR-GAN, la máscara de severidad de artefacto (AMG) se obtiene combinando la imagen procesada mediante interpolación lineal con la imagen corrupta; dicha máscara guía una atención que prioriza la restauración del foreground lesionado, reduciendo la probabilidad de hallucinations y mejorando la conservación de la estructura anatómica.

La Figura 11 muestra de manera esquemática la arquitectura CALIMAR-GAN, donde se observa la integración de entradas múltiples y la incorporación de un módulo de atención guiada por máscara para focalizar la corrección en las regiones afectadas (Scardigno et al., 2025).

Figura 11

Esquema Arquitectura CALIMAR-GAN



Nota. Scardigno et al., 2025, p. 5

Estrategias de Datos y Entrenamiento


La carencia de pares clínicos “limpio-corrupto” es un desafío central. Para sortearlo se utilizan principalmente dos estrategias: (i) simulación controlada de metales insertados en imágenes limpias para generar ground truth sintético, y (ii) entrenamiento no emparejado apoyado por estructuras adversariales y pérdidas de consistencia. Una práctica recomendada es el entrenamiento mixto (simulado + casos reales), que atenúa el sesgo de simulación y favorece la generalización a imágenes clínicas; CALIMAR-GAN ilustra cómo combinar grandes conjuntos sintéticos (obtenidos mediante augmentación de máscaras metálicas reales) con subconjuntos clínicos para reducir la brecha de dominio. La generación de máscaras realistas, su rotación,

escalado y colocación anatómicamente plausible es clave para exponer a la red a una amplia variedad geométrica de implantes y posiciones.

La Figura 12 ilustra el proceso de construcción del conjunto de datos utilizado para el entrenamiento de CALIMAR-GAN, que combina imágenes clínicas con simulaciones generadas a partir de máscaras metálicas extraídas de casos reales (Scardigno et al., 2025).

Figura 12

Construcción del Conjunto de Datos Mediante Máscaras Metálicas



Nota. Scardigno et al., 2025, p. 4

Funciones de Pérdida y Evaluación

El diseño de la función objetivo condiona el equilibrio entre fidelidad píxel a píxel y preservación de textura. Las combinaciones típicas incluyen pérdidas L1/L2 (fidelidad), pérdidas perceptuales (features extraídas de redes preentrenadas) y pérdidas adversariales (GAN),


complementadas por términos de identidad y consistencia de ciclo en métodos no emparejados. Para la evaluación, cuando existe referencia, se usan PSNR, SSIM y RMSE; en ausencia de referencia directa se recurre a métricas distribution-based como FID y a evaluaciones basadas en tareas clínicas siendo estas últimas determinantes para juzgar la utilidad clínica de la corrección. CALIMAR-GAN reporta mejoras en métricas píxel-basadas en datos simulados y demuestra correlación entre FID y PSNR en sus experimentos, además de mejoras en tareas downstream como la segmentación vertebral (Dice), lo que subraya la necesidad de medir el impacto funcional, no solo la apariencia.

La Figura 13 muestra ejemplos comparativos de reducción de artefactos utilizando distintas estrategias de entrenamiento en CALIMAR-GAN, evidenciando mejoras en métricas de fidelidad (PSNR, SSIM) y en el desempeño funcional evaluado mediante segmentación (Scardigno et al., 2025).

Figura 13

Ejemplos de Máscaras Binarias Empleadas en la Construcción del Conjunto de Datos

Simulado.



Nota. Scardigno et al., 2025, p. 8

Marco Conceptual

Tabla 1

Términos y Definición Sobre CNN Y Reducción de Artefactos Metálicos En TC

Término	Definición
CNN (Redes Neuronales Convolucionales)	Modelo de aprendizaje profundo que procesa imágenes mediante convoluciones jerárquicas para extraer patrones espaciales complejos.
Dominio de imagen (Image-domain)	Método en el cual la red corrige imágenes ya reconstruidas de TC, aprendiendo un mapeo entre imágenes con artefactos y sus versiones corregidas.
Dominio de proyección (Projection Domain o sinograma)	Enfoque que actúa sobre los datos de proyección antes de la reconstrucción, corrigiendo directamente la información corrupta en el sinograma.
Enfoques híbridos	Estrategias que combinan módulos físicos de reconstrucción con redes neuronales profundas para mantener consistencia con los datos medidos.
Skip connections	Conexiones entre capas de codificación y decodificación que permiten recuperar información espacial perdida en la compresión.
Cycle-consistent	Principio de entrenamiento que obliga a que una imagen traducida a otro dominio y devuelta al original conserve la información inicial.
Máscara de severidad de artefacto (AMG)	Imagen binaria que indica la localización e intensidad de los artefactos metálicos, guiando la atención de la red.
Entrenamiento mixto (simulado + real)	Estrategia que combina imágenes sintéticas con datos clínicos para mejorar la generalización.
Funciones de pérdida (Loss functions)	Conjunto de métricas de entrenamiento: adversarial, de ciclo, de identidad y de fidelidad (L1/L2).
Hallucinations	Fenómeno en el cual la red genera estructuras anatómicas inexistentes pero plausibles.
PSNR, SSIM y RMSE	Métricas cuantitativas que evalúan fidelidad y similitud estructural.
FID (Fréchet Inception Distance)	Métrica de distribución que evalúa la similitud estadística entre imágenes corregidas y reales.
Dice coefficient	Medida de superposición entre segmentación automática y manual, usada para evaluar impacto clínico.
Limitaciones	Falta de robustez inter-scanner, persistencia de artefactos físicos y ausencia de validación multicéntrica.

Nota. La tabla sintetiza los principales conceptos, arquitecturas y limitaciones asociados al uso CNN en la reducción de artefactos metálicos en TC, de acuerdo con lo reportado por Scardigno et al. (2025).

Marco Normativo

El uso de información científica y material protegido por derechos de autor en la elaboración de trabajos académicos se encuentra regulado por la Ley 23 de 1982, la cual otorga a los autores derechos patrimoniales y morales sobre sus obras. Posteriormente, la Ley 1915 de 2018 amplió dichas disposiciones, reforzando la protección de los derechos morales, como la integridad de la obra y el reconocimiento de la autoría. En este contexto, toda cita, figura o tabla debe ser referenciada con precisión, conforme a los lineamientos internacionales de citación académica, en este caso, las normas APA (7.ª edición).

De igual manera, la Ley 1581 de 2012 sobre protección de datos personales establece obligaciones en cuanto al manejo de información sensible, como es el caso de datos clínicos empleados en investigaciones con inteligencia artificial. En el ámbito sanitario, la Ley Estatutaria 1751 de 2015 reconoce el derecho fundamental a la salud, lo que implica garantizar que el uso de tecnologías emergentes no afecte la dignidad, la autonomía ni la seguridad de los pacientes.

Proyecto de Ley sobre Inteligencia Artificial en Colombia

El 28 de julio de 2025, fue radicado en el Congreso de la República el Proyecto de Ley para la regulación, uso y desarrollo de la inteligencia artificial en Colombia. Este documento constituye un esfuerzo pionero en el país para establecer principios rectores del uso de la IA como un asunto de interés público y estratégico.

Dicho proyecto constituye un avance normativo fundamental para garantizar un uso ético, responsable y seguro de estas tecnologías. En su articulado, se reconoce que las aplicaciones de la IA en áreas de alto impacto social, como la salud, requieren estándares más rigurosos de control y supervisión por su potencial efecto directo en la vida, la integridad y la dignidad de las personas.

Bajo este contexto, el proyecto establece que la IA aplicada en el ámbito sanitario debe regirse por los principios de transparencia, explicabilidad, trazabilidad, seguridad, responsabilidad y supervisión humana. Estos lineamientos buscan que los algoritmos utilizados en procesos clínicos, tales como los aplicados en la TC, no funcionen como sistemas autónomos desligados de la práctica médica, sino como herramientas complementarias al juicio clínico profesional.

El texto también resalta la importancia de contar con protocolos sectoriales específicos en salud, orientados a la validación clínica, la estandarización de procedimientos y la interoperabilidad entre instituciones médicas. Dichos protocolos deben garantizar que los resultados producidos por modelos de aprendizaje profundo, como las CNN para reducción de artefactos metálicos, sean reproducibles, verificables y ajustados a criterios científicos sólidos.

De igual manera, el proyecto exige la construcción y el uso de bases de datos clínicas seguras, representativas y anonimizadas, lo que constituye un requisito indispensable para entrenar modelos de IA sin vulnerar la privacidad de los pacientes ni incurrir en sesgos que comprometan la equidad diagnóstica. A esto se suma la obligación de obtener consentimiento informado en aquellos casos en que el uso de IA incida en la toma de decisiones médicas, garantizando así el respeto al principio de autonomía del paciente.

Finalmente, la propuesta legislativa subraya que toda aplicación de IA en salud debe ser sometida a procesos de evaluación multicéntrica y a un monitoreo permanente por parte de las autoridades competentes, en aras de preservar la seguridad clínica, la justicia en el acceso y la confianza social en el uso responsable de estas tecnologías

Normativas Internacionales en IA Aplicada a la Salud

A nivel global, la Organización Mundial de la Salud (OMS) publicó en 2021 el informe *Ética y gobernanza de la inteligencia artificial para la salud*, donde se establecen seis principios orientadores: protección de la autonomía humana, promoción del bienestar y la seguridad, transparencia, responsabilidad, inclusión y sostenibilidad. Estos lineamientos insisten en que la IA debe complementar, mas no sustituir, el juicio clínico humano.

De manera paralela, la Unión Europea, a través de la propuesta de Reglamento de Inteligencia Artificial (IA Act), considera las aplicaciones médicas como de alto riesgo, imponiendo requisitos estrictos de trazabilidad, documentación técnica, validación clínica y supervisión humana. Este enfoque busca minimizar riesgos diagnósticos, garantizar la fiabilidad de los resultados y proteger los derechos fundamentales de los pacientes.

Marco Metodológico

La presente investigación adopta un enfoque cualitativo, sustentado en una revisión narrativa de la literatura científica relacionada con el uso CNN, particularmente los modelos U-Net y GAN, en la reducción de artefactos y la mejora de la calidad de imagen en TC. Este tipo de estudio permite realizar un análisis interpretativo y crítico de los hallazgos reportados en publicaciones recientes, sin recurrir a procedimientos estadísticos o experimentales directos.

El propósito metodológico radica en analizar y sintetizar la evidencia existente sobre la aplicación de algoritmos de inteligencia artificial en radiología, con el fin de identificar avances, limitaciones y perspectivas futuras de esta tecnología en el ámbito clínico. Para ello, el desarrollo del proceso investigativo se estructuró en cuatro fases articuladas, que garantizaron coherencia, rigurosidad y trazabilidad en la construcción del conocimiento.

Fase I. Contextualización del Problema de Investigación

En esta primera fase se identificó y delimitó la problemática, orientada a la comprensión del impacto que generan los artefactos en la calidad de imagen en TC y cómo estos afectan la interpretación diagnóstica y la seguridad del paciente.

El grupo de investigación elaboró un árbol de problemas, mediante el cual se analizaron las causas, efectos y consecuencias de los artefactos en los procesos de reconstrucción de imagen. A partir de esta reflexión, se formuló el planteamiento del problema y su justificación, estableciendo la pertinencia del estudio sobre el uso de CNN como herramienta innovadora para la optimización de imágenes diagnósticas.

Fase II. Análisis y Construcción del Marco Teórico

En esta etapa se desarrolló la revisión documental que sustenta teóricamente la investigación.

Para ello, se elaboró una matriz bibliográfica con referencias recientes y relevantes, extraídas de bases de datos académicas como *PubMed*, *Scopus*, *IEEE Xplore*, *ScienceDirect*, *SpringerLink* y *Google Scholar*, priorizando publicaciones entre los años 2014 y 2025, en idioma inglés y español.

Se emplearon descriptores específicos tales como convolutional neural networks, computed tomography artifacts, image reconstruction, deep learning in radiology y artifact reduction.

Los textos seleccionados se analizaron en función de su autoría, año, metodología, aportes y relevancia científica, lo que permitió construir el marco teórico, conceptual y normativo. Este incluyó los fundamentos técnicos de la TC, los factores que afectan la calidad de imagen, los principios de las CNN, y las disposiciones legales vigentes en materia de derechos de autor e inteligencia artificial en Colombia.

La información recolectada fue sistematizada de forma manual, asegurando la coherencia temática y la trazabilidad de las fuentes, bajo los lineamientos de la norma APA (7.^a edición).

Fase III. Aplicación Metodológica y Formulación de Objetivos

Durante esta fase, se definió el diseño metodológico de la investigación, enmarcado dentro del paradigma cualitativo y sustentado en la revisión narrativa como estrategia principal. Este enfoque permitió integrar diversas perspectivas teóricas y empíricas, facilitando un análisis inductivo en el que las categorías emergieron de los hallazgos de la literatura revisada.

Asimismo, se formularon los objetivos general y específicos, orientados al análisis del uso de CNN (modelos U-Net y GAN) en la reducción de artefactos en TC.

Para garantizar la fiabilidad del proceso, se diseñó una tabla comparativa de estudios, en la que se consignaron los autores, metodologías, resultados y limitaciones de cada investigación.

Este instrumento sirvió como base para identificar los vacíos de conocimiento y las tendencias actuales del campo.

Fase IV. Consolidación de Resultados y Elaboración del Informe Final

En la fase final, se analizó de manera crítica la información recopilada, identificando patrones, coincidencias y divergencias entre los estudios revisados.

El proceso de síntesis permitirá elaborar conclusiones reflexivas sobre la eficacia y las limitaciones de las CNN en la reducción de artefactos, además de destacar los desafíos técnicos, éticos y normativos asociados a su implementación clínica.

En la siguiente tabla se sintetizan las fases que conformaron el proceso metodológico desarrollado en la investigación.

Tabla 2

Síntesis de las Fases Metodológicas del Estudio

Fase	Actividad principal	Propósito
Fase I	Identificación del problema y formulación del árbol de causas y efectos	Definir la problemática de los artefactos en TC
Fase II	Revisión y análisis de literatura científica	Fundamentar teóricamente la investigación
Fase III	Definición del diseño metodológico y formulación de objetivos	Organizar la estructura de análisis y orientar la revisión
Fase IV	Interpretación crítica y redacción del informe final	Integrar resultados y conclusiones del estudio

Nota. Autoría propia.

Revisión Documental y Análisis de Fuentes Científicas

Como parte fundamental del proceso metodológico, se efectuó una revisión narrativa y analítica de la literatura científica relacionada con la presencia de artefactos en imágenes de TC y el uso de CNN como estrategia para su reducción.

La búsqueda bibliográfica se llevó a cabo en bases de datos académicas de alto reconocimiento como PubMed, Scopus, IEEE Xplore, ScienceDirect, SpringerLink y Google Scholar, empleando combinaciones de descriptores en inglés y español tales como computed tomography artifacts, deep learning in radiology, convolutional neural networks, image reconstruction y artifact reduction.

Para garantizar la validez y pertinencia de la información, se aplicaron criterios de inclusión y exclusión previamente establecidos, con el fin de seleccionar únicamente estudios científicos relevantes para el objetivo del presente trabajo.

Criterios de Inclusión

Publicaciones comprendidas entre 2014 y 2025.

Documentos en texto completo y en idiomas español o inglés.

Artículos científicos, revisiones sistemáticas, tesis o trabajos investigativos que aborden el uso de IA y CNN en la reconstrucción o mejora de imágenes de TC.

Investigaciones que analicen los efectos de los artefactos sobre la calidad de imagen o propongan métodos para su reducción o mitigación.

Fuentes que aporten enfoques técnicos, clínicos o éticos vinculados al empleo de algoritmos de aprendizaje profundo en radiología.

Criterios de Exclusión

Publicaciones sin respaldo científico o sin acceso completo.

Estudios centrados en modalidades distintas a la TC (como RM o radiografía convencional).

Documentos que no presenten relación directa con la reconstrucción de imagen o reducción de artefactos.

Fuentes no académicas (blogs, artículos de opinión o textos sin metodología explícita).

Una vez seleccionadas las fuentes, se procedió a su organización en una tabla comparativa donde se consignaron los autores, año, tipo de artículo, metodología, principales hallazgos, importancia para la investigación. Esta herramienta permitió identificar los vacíos de conocimiento, las aproximaciones metodológicas más empleadas y las proyecciones tecnológicas del campo, constituyéndose en la base del análisis crítico desarrollado en el presente trabajo.

A continuación se presentan las fuentes analizadas sobre los artefactos en TC, con el propósito de identificar sus principales causas, tipos y métodos de corrección.

Tabla 3

Clasificación de la Literatura Revisada Sobre Artefactos en Tomografía Computarizada

Título del artículo	Tipo de literatura	Cumple criterios de inclusión	Justificación de inclusión o exclusión
Artefactos y artificios frecuentes en tomografía computada y resonancia magnética, Sartori et al. (2015).	Artículo científico descriptivo	Si	Describe en detalle los principales tipos de artefactos en TC y RM, sus causas físicas y técnicas, y las estrategias de mitigación. Constituye una fuente fundamental para la comprensión técnica de la problemática.
Tomografía computarizada dirigida a técnicos superiores en imagen para el diagnóstico, Costa, J; Soria, A. (2015).	Libro técnico-académico	Si	Proporciona una descripción exhaustiva del funcionamiento del equipo de TC y los factores que originan artefactos, con enfoque práctico dirigido al personal técnico.
Magnetic Resonance Image Artifacts: Causes and Reduction Strategies, Li, X., & Tan, J. (2019).	Artículo científico	No	Se centra en los artefactos de resonancia magnética y no en TC, por lo que no cumple el criterio de modalidad.
Noise and Motion Artifacts in Ultrasound Imaging: Clinical Implications, Rivera, L., & Gómez, E. (2020).	Artículo científico	No	Aunque aborda artefactos en imágenes médicas, el estudio se limita a ultrasonido, sin relación directa con TC

Nota. Autoría propia.

A continuación se presentan literatura sobre el uso de IA y CNN en la reconstrucción o mejora de imágenes de TC.

Tabla 4

Clasificación de Literatura que Aborden el Uso de IA y CNN en la Reconstrucción o Mejora de Imágenes de TC.

Título del artículo	Tipo de literatura	Cumple criterios de inclusión	Justificación de inclusión o exclusión
Análisis del uso y eficacia de las inteligencias artificiales aplicadas a la optimización de imágenes médicas, Higuera Mosquera et al. (2025)	Trabajo investigativo académico	Sí	Cumple plenamente los criterios. Analiza la aplicación de la inteligencia artificial en la optimización de imágenes diagnósticas, aportando una base conceptual sólida y aplicable al estudio.
Avances en el aprendizaje profundo supervisado y no supervisado para la reducción de artefactos metálicos en TC, Kleber et al. (2024)	Artículo científico comparativo	Sí	Cumple con los criterios temáticos y metodológicos. Compara modelos CNN y GAN aplicados a la reducción de artefactos metálicos, ofreciendo evidencia técnica actualizada.
Advances in Metal Artifact Reduction in CT Images: A Review of Traditional and Novel Techniques, Selles et al. (2024)	Revisión sistemática	Sí	Cumple los criterios de inclusión. Revisa métodos tradicionales y recientes para la reducción de artefactos en TC, resaltando el potencial del aprendizaje profundo.
CALIMAR-GAN: Una red de atención guiada por máscara para reducción de artefactos metálicos en TC, Scardigno et al. (2025)	Artículo científico experimental	Sí	Cumple todos los criterios técnicos y temáticos. Presenta una red GAN con atención guiada que mejora la calidad de imagen preservando detalles anatómicos.
Reducción de artefactos metálicos basada en aprendizaje profundo aplicado a imágenes de TC, Arabi & Zaidi (2021)	Artículo científico experimental	No	Aunque se relaciona con el tema, no cumple completamente los criterios, ya que su enfoque es técnico-específico y carece de aplicación clínica o contextual.

Título del artículo	Tipo de literatura	Cumple criterios de inclusión	Justificación de inclusión o exclusión
Reducción de artefactos metálicos para tomografía computarizada mediante modelo U-Net, Zhu et al. (2019)	Artículo científico experimental	No	Se excluye por no cumplir los criterios de idioma y disponibilidad completa, aunque aborda la temática de U-Net en TC.
Avances en la reducción de artefactos metálicos en tomografía computarizada, Greffier et al. (2022)	Revisión narrativa	No	Se excluye por ser una revisión técnica breve que no profundiza en la aplicación de redes neuronales o IA en la reconstrucción de imagen.

Nota. Autoría propia.

Ampliación Bibliográfica de Las Fuentes Incluidas y su Respectivo Aporte e Importancia a la Investigación

Tabla 5

Análisis de Fuentes Utilizadas para la Fundamentación Conceptual Sobre Artefactos en TC

Autor(es)	Año	Título del artículo	Tipo de literatura	Aporte a la investigación
Sartori, P., Rozowykniat, M., Siviero, L., Barba, G., Peña, A., Mayol, N., & Ortiz, A.	2015	Artefactos y artificios frecuentes en tomografía computada y resonancia magnética.	Artículo científico de revisión	Aporta una clasificación clara y actualizada de los artefactos que se presentan en la TC, describiendo sus causas físicas, de reconstrucción y de adquisición. Además, ofrece ejemplos visuales y recomendaciones prácticas para su identificación y reducción, lo que permitió sustentar la descripción conceptual del fenómeno en el trabajo investigativo.
Costa, J., & Soria, J. A.	2015	Tomografía computarizada dirigida a técnicos superiores en imagen para el diagnóstico.	Libro técnico-formativo	Brinda fundamentos teóricos sobre la formación de imágenes en TC, los principios físicos que originan los artefactos y su repercusión en la calidad diagnóstica. Sirvió de apoyo conceptual para explicar los mecanismos técnicos asociados a la generación de artefactos y su clasificación.

Nota. Autoría propia

Tabla 6

Análisis de Estudios Sobre el Uso de IA Y CNN en la Reconstrucción o Mejora de Imágenes de TC.

Autor(es)	Año	Título del artículo	Metodología	Principales hallazgos	Importancia para la investigación
Selles et al.	2024	Advances in Metal Artifact Reduction in CT Images: A Review of Traditional and Novel Techniques	Revisión de literatura que compara métodos tradicionales y enfoques basados en aprendizaje profundo para la reducción de artefactos.	Identifica que los algoritmos de inteligencia artificial superan las técnicas convencionales de interpolación y filtrado en la corrección de artefactos.	Fundamenta la necesidad de incorporar modelos de IA en los protocolos clínicos de reconstrucción de imagen.
Higuera Mosquera et al.	2025	Análisis del uso y eficacia de las inteligencias artificiales aplicadas a la optimización de imágenes médicas	Investigación descriptiva sobre el papel de la IA en la mejora de imágenes diagnósticas.	Resalta la utilidad de los algoritmos de IA en la optimización de la calidad de imagen y su potencial en entornos hospitalarios.	Conecta la teoría de IA con su aplicación práctica en radiología digital.
Kleber et al.	2024	Avances en el aprendizaje profundo supervisado y no supervisado para la reducción de artefactos metálicos en TC	Estudio comparativo de modelos CNN y GAN aplicados a la eliminación de artefactos metálicos.	Concluye que los modelos híbridos GAN mejoran la consistencia visual y reducen los errores de reconstrucción.	Aporta evidencia técnica actualizada sobre la eficacia de las redes generativas en TC.
Scardigno et al.	2025	CALIMAR-GAN: Una red de atención guiada por máscara para reducción de artefactos metálicos en TC	Investigación experimental con arquitectura GAN y módulos de atención guiada por máscara.	Logra una corrección localizada de artefactos metálicos preservando los detalles anatómicos originales.	Constituye uno de los aportes más recientes e innovadores en reconstrucción mediante aprendizaje profundo.

Nota. Autoría propia

Análisis y Resultados de la Literatura Revisada

Mediante la revisión bibliográfica se pudo destacar una evolución significativa en la aplicación de CNN para la reconstrucción y optimización de imágenes en TC. De los estudios revisados, se desprende una tendencia consolidada hacia la sustitución de algoritmos tradicionales como la retroproyección filtrada (FBP) y la reconstrucción iterativa por modelos basados en aprendizaje profundo, debido a su capacidad para reducir artefactos y preservar la fidelidad anatómica.

En el conjunto de investigaciones analizadas (Selles et al., 2024; Kleber et al., 2024; Scardigno et al., 2025; Higuera Mosquera et al., 2025), se observa una coincidencia en que las CNN, y en particular las arquitecturas U-Net y GAN, ofrecen una mejora cuantificable en parámetros objetivos de calidad de imagen, tales como el PSNR (Peak Signal-to-Noise Ratio) y el SSIM (Structural Similarity Index), al tiempo que reducen la distorsión visual y los artefactos metálicos. Estos resultados demuestran que los modelos de aprendizaje profundo superan las limitaciones de los métodos determinísticos al aprender patrones complejos de degradación y reconstrucción directamente desde los datos.

El modelo U-Net destaca por su capacidad para mantener la coherencia estructural entre las regiones afectadas por artefactos y los tejidos circundantes. Su arquitectura tipo encoder-decoder, con skip connections, permite preservar detalles finos y mejorar la delimitación anatómica, evitando la sobrecorrección o pérdida de información diagnóstica. Este comportamiento fue confirmado por Kleber et al. (2024), quienes evidenciaron una mejor conservación de los bordes y texturas en comparación con los métodos iterativos convencionales.

Por su parte, los modelos GAN (Generative Adversarial Networks), especialmente en versiones híbridas como CALIMAR-GAN (Scardigno et al., 2025), integran mecanismos de atención guiada que focalizan la corrección sobre las zonas de mayor distorsión, minimizando el impacto en las áreas sanas. Este enfoque introduce un componente perceptual que favorece la naturalidad visual de la imagen reconstruida, generando resultados más realistas y clínicamente interpretables. Las métricas empleadas FID y coeficiente Dice, reflejan no solo una mejora en la similitud estadística con las imágenes reales, sino también un incremento en la precisión de tareas clínicas secundarias, como la segmentación anatómica.

Asimismo, los estudios consultados coinciden en la importancia de combinar datos simulados y reales durante el entrenamiento de las redes. El entrenamiento mixto propuesto por Scardigno et al. (2025) demostró ser una estrategia efectiva para reducir el sesgo de simulación, incrementando la robustez del modelo ante variaciones en los escáneres o protocolos de adquisición.

Desde el punto de vista técnico, se identificó que los métodos de reducción de artefactos basados en CNN son especialmente eficaces en artefactos metálicos y de endurecimiento del haz, mientras que los generados por movimiento o proyección incompleta siguen representando un desafío para los algoritmos actuales. Además, algunos autores advierten sobre el riesgo de hallucinations, lo que plantea la necesidad de fortalecer las estrategias de regularización y supervisión clínica durante la fase de validación.

En términos de aplicabilidad, los resultados obtenidos a partir de la literatura analizada confirman que las redes neuronales convolucionales (CNN), y en particular las arquitecturas U-Net y GAN, constituyen actualmente las herramientas más eficaces para la reconstrucción y mejora de imágenes en tomografía computarizada (TC). Los diversos autores coinciden en que

estos modelos logran una reducción sustancial de artefactos metálicos y una preservación superior de los detalles anatómicos frente a los métodos clásicos de FBP) reconstrucción iterativa. La U-Net, gracias a sus skip connections y a su arquitectura tipo encoder-decoder, ha demostrado especial efectividad en la reconstrucción de bordes y texturas finas, permitiendo obtener cortes más uniformes y anatómicamente coherentes, incluso en regiones adyacentes a materiales de alta densidad.

Por su parte, las GAN y en particular las variantes con atención guiada por máscara como el modelo CALIMAR-GAN propuesto por Scardigno et al. (2025), han demostrado una capacidad adaptativa más alta al focalizar la corrección sobre zonas específicas afectadas por artefactos, reduciendo la pérdida de información en tejidos no comprometidos. Este avance se refleja en mejoras cuantitativas documentadas en métricas como PSNR, SSIM y FID, así como en indicadores funcionales como el coeficiente Dice en tareas de segmentación. Tales resultados confirman que las redes basadas en aprendizaje profundo no solo aumentan la calidad visual, sino que también mantienen la utilidad clínica de la imagen corregida, lo que representa un paso decisivo hacia su validación diagnóstica.

Sin embargo, la revisión evidencia también que la adopción de estas técnicas en entornos hospitalarios continúa siendo limitada por tres barreras fundamentales. Primero, la escasez de bases de datos clínicas abiertas y heterogéneas, lo cual impide entrenar modelos con representaciones anatómicas y tecnológicas diversas, generando sesgos y limitando la generalización interinstitucional (Higuera Mosquera et al., 2025). Segundo, la falta de estandarización metodológica en cuanto a protocolos de adquisición, procesamiento y evaluación de resultados, que dificulta la comparación objetiva entre estudios y la reproducibilidad de los hallazgos. Y tercero, la ausencia de validaciones multicéntricas con cohortes amplias, necesarias

para establecer niveles de precisión y confiabilidad estadística que respalden su implementación clínica a gran escala.

En conjunto, la evidencia revisada permite afirmar que las CNN, U-Net y GAN se perfilan como herramientas de alta proyección científica y clínica en la optimización de imágenes de TC, al ofrecer una integración balanceada entre corrección algorítmica y preservación anatómica. No obstante, su consolidación como estándar de práctica depende de avances sostenidos en la construcción de bases de datos seguras y anonimizadas, el desarrollo de marcos normativos internacionales y nacionales como el Proyecto de Ley colombiano sobre IA (2025), y la implementación de estrategias de evaluación clínica colaborativa que garanticen la eficacia, seguridad y reproducibilidad de sus resultados en entornos reales de diagnóstico por imágenes.

Tabla 7

Comparación de Resultados en Reducción de Artefactos y Optimización de Imagen en TC

Mediante IA de Literatura Revisada

Estudio (autor, año)	Arquitectura / Enfoque	Dominio (imagen / sinograma / dual)	Métricas reportadas (valores reales)	Resultados principales / interpretación científica
Selles et al. (2024) - <i>Advances in metal artifact reduction in CT images</i>	DL-MAR (deep residual CNN) comparado con O-MAR y monoE 130 keV	Imagen (post-reconstrucción)	Δ CNR \uparrow significativo ($p \leq 0.010$); reducción de artefactos $> 90\%$; mejora subjetiva en calidad de imagen	El modelo DL-MAR superó a los algoritmos comerciales (O-MAR) y redujo la severidad de artefactos metálicos en pacientes con prótesis de cadera, demostrando validez clínica y mayor confianza diagnóstica.
Scardigno et al. (2025) - <i>CALIMAR-GAN: Unpaired mask-guided attention network</i>	GAN con atención guiada por máscara y datos no emparejados	Dual (sinograma + imagen)	Simulado \rightarrow PSNR = 31.7; SSIM = 0.877; FID = 22.1	Clínico \rightarrow FID = 32.7

Estudio (autor, año)	Arquitectura / Enfoque	Dominio (imagen / sinograma / dual)	Métricas reportadas (valores reales)	Resultados principales / interpretación científica
Kleber et al. (2024) - <i>Advancements in supervised deep learning for MAR in CT</i>	Revisión sistemática (14 estudios de CNN, U-Net, GAN, DuDoNet++)	Sinograma, Imagen y Dual	Valores medios reportados: • Sinograma: PSNR 36.9 / SSIM 0.91 (CNN Mai et al.) • Imagen: PSNR 42.9 / SSIM 0.99 (OSCNet+) • Dual: PSNR 44.8 / SSIM 0.996 (MoDDNet)	En > 90 % de los casos, las CNN supervisadas mejoraron PSNR y SSIM respecto a imágenes sin corrección y frente a métodos no DL (NMAR, LI, FSMAR). Los modelos dual-domain (MoDDNet, InDuDoNet+) mostraron el mejor rendimiento (PSNR ↑ 17 – 20 dB).
Higuera Mosquera et al. (2025) - <i>Análisis del uso y eficacia de las inteligencias artificiales en TC</i>	Revisión documental (40 artículos 2020-2024, IA y DL en TC diagnóstica)	Aplicaciones clínicas generales (reconstrucción, detección, segmentación)	Mejora media ≈ 25 % en sensibilidad diagnóstica; reducción de ruido > 30 %; reducción de dosis hasta 40 % sin pérdida de calidad diagnóstica	Confirma que la IA en TC mejora la eficiencia clínica y la precisión diagnóstica. El aprendizaje profundo supera el rendimiento humano en tareas de detección automática de patologías, aunque persiste el reto de generalización y regulación en Colombia.

Nota. Autoría propia.

Discusión

El análisis comparativo de los estudios revisados evidencia una evolución sustancial en la aplicación de CNN y arquitecturas derivadas para la reducción de artefactos metálicos y optimización de la calidad de imagen TC. Los hallazgos muestran que el aprendizaje profundo ha superado las limitaciones de los métodos tradicionales como la interpolación lineal (LI), el normalized metal artifact reduction (NMAR) y los enfoques basados en filtered back projection (FBP) al ofrecer mejoras cuantitativas y perceptuales significativas.

En el estudio de Selles et al. (2024), el uso del algoritmo DL-MAR, basado en CNN residuales, demostró una reducción superior al 90 % en la severidad de los artefactos y un aumento significativo en la relación contraste-ruido (CNR) en pacientes con prótesis de cadera, con diferencias estadísticamente significativas ($p \leq 0.010$). Además, los observadores radiológicos reportaron una mayor confianza diagnóstica en las imágenes corregidas, lo cual respalda la aplicabilidad clínica del modelo. Estos resultados validan que los métodos de aprendizaje profundo no solo mejoran métricas objetivas, sino también la percepción visual del especialista, un factor clave en entornos hospitalarios.

Para sintetizar los hallazgos y contrastar los aportes de cada investigación, se elaboró la Tabla 8, donde se presentan de forma comparativa los principales resultados cuantitativos, los desafíos científicos identificados y las soluciones propuestas por los autores. Esta organización permite visualizar la evolución metodológica y las tendencias actuales en el uso de inteligencia artificial para la reducción de artefactos metálicos en tomografía computarizada.

Tabla 8.

Síntesis Analítica de la Discusión: Resultados, Desafíos y Soluciones Propuestas en la

Reducción de Artefactos Mediante IA

Estudio (año)	Hallazgos principales	Desafíos científicos identificados	Propuestas de solución / perspectivas futuras	Implicación clínica o diagnóstica
Selles et al. (2024)	DL-MAR redujo en >90 % la severidad de artefactos y mejoró significativamente el CNR ($p \leq 0.010$). Mayor confianza diagnóstica del radiólogo.	Limitada generalización del modelo a otros tipos de prótesis o metales; dependencia de datasets específicos.	Creación de modelos multimetálicos y ampliación del entrenamiento con bases de datos clínicas diversas.	Incremento directo en la calidad diagnóstica y reducción de repeticiones de TC.
Scardigno et al. (2025)	CALIMAR-GAN (no supervisado) obtuvo PSNR = 31.7 dB, SSIM = 0.877, FID = 22.1; mantuvo textura anatómica con mínima distorsión.	Riesgo de <i>hallucinations</i> o generación de detalles falsos; necesidad de correlación clínica.	Implementar pérdidas híbridas (consistencia + perceptual) y validación por especialistas.	Posibilita el entrenamiento sin datos emparejados y favorece el uso clínico con datos reales.
Kleber et al. (2024)	En 14 estudios revisados, modelos dual-domain alcanzan PSNR = 44.8 dB, SSIM = 0.996 (MoDDNet). Mejor desempeño global frente a métodos clásicos.	Falta de estandarización entre escáneres y ausencia de sinogramas accesibles.	Consortios multicéntricos y protocolos abiertos de validación inter-scanner.	Elevada reproducibilidad y potencial para implementación universal en MAR.
Higuera Mosquera et al. (2025)	La IA mejoró 25 % la sensibilidad diagnóstica y redujo 40 % la dosis sin pérdida de calidad.	Limitaciones en infraestructura y regulación nacional; brecha en formación técnica.	Fortalecer la capacitación profesional, actualización normativa y adopción ética de IA en radiología.	Optimiza la eficiencia del flujo de trabajo radiológico y promueve la protección radiológica.

Nota. Autoría propia.

Como se observa en la Tabla 8, todos los autores coinciden en el papel protagónico de las CNN en la mejora de la calidad de imagen y en la necesidad de protocolos estandarizados que garanticen su validez clínica. Estos aspectos se discuten en detalle a continuación.

Por su parte, Scardigno et al. (2025) introducen el modelo CALIMAR-GAN, una arquitectura adversarial no supervisada guiada por máscaras de atención, que alcanza PSNR = 31.7 dB y SSIM = 0.877 en datos simulados, con un FID = 22.1, y un FID clínico de 32.7, valores que confirman una alta correspondencia entre la calidad cuantitativa y perceptual. La correlación observada entre FID y PSNR ($r \approx 0.89$) sugiere coherencia entre las métricas físicas y la percepción visual, consolidando el valor del enfoque mask-guided attention para una corrección localizada de los artefactos sin afectar el tejido circundante. Este estudio marca un avance metodológico relevante al prescindir de datos emparejados para el entrenamiento, lo que amplía su aplicabilidad a contextos clínicos reales donde los sinogramas originales no están disponibles.

En la revisión sistemática de Kleber et al. (2024), que integró 14 estudios representativos, se evidencia que los modelos de dominio dual (combinando información del sinograma y de la imagen reconstruida) presentan los resultados más robustos, con PSNR promedio = 44.8 dB y SSIM = 0.996 en el modelo MoDDNet, superando ampliamente los valores de los métodos de dominio único (PSNR \approx 36–42 dB). Esta superioridad se atribuye a la capacidad de las arquitecturas duales para preservar la fidelidad cuantitativa mientras atenúan los artefactos de reconstrucción. Los autores concluyen que el futuro de la reducción de artefactos metálicos depende de integrar estrategias híbridas y módulos de atención adaptativa que optimicen simultáneamente la consistencia geométrica y la textura anatómica.

El estudio de Higuera Mosquera et al. (2025), amplía el análisis hacia la práctica clínica nacional, documentando mejoras de hasta 40 % en la reducción de dosis de radiación y 25 % en la sensibilidad diagnóstica gracias a la integración de sistemas de inteligencia artificial en los flujos de trabajo de TC. Además, se reporta una disminución del ruido en más del 30 %, manteniendo la calidad diagnóstica. Estos resultados reflejan el impacto transversal de la IA en la eficiencia y la seguridad del paciente, alineándose con las políticas de optimización y protección radiológica recomendadas por la Organización Mundial de la Salud (OMS) y la IAEA. Sin embargo, el estudio también resalta desafíos en materia de infraestructura tecnológica, capacitación profesional y regulación ética, particularmente en el contexto colombiano.

De manera integral, los cuatro estudios revisados coinciden en que los algoritmos basados en CNN, tanto supervisados como no supervisados, superan de forma consistente los métodos convencionales de reducción de artefactos. Las métricas cuantitativas (PSNR, SSIM, CNR) y las métricas perceptuales (FID) convergen en señalar una mejora generalizada en la calidad de imagen. No obstante, se identifican tres desafíos científicos clave:

Disponibilidad limitada de sinogramas clínicos: la mayoría de los modelos se entrenan con datos simulados, lo que puede afectar su generalización. Se propone la creación de repositorios multicéntricos anonimizados que faciliten la validación clínica de los algoritmos (Kleber et al., 2024).

Riesgo de generación de estructuras ficticias (hallucinations): especialmente en redes adversariales, se requieren funciones de pérdida híbridas que incluyan términos de consistencia anatómica y penalización de falsos positivos (Scardigno et al., 2025).

Estandarización y regulación: los autores destacan la necesidad de protocolos de evaluación armonizados y lineamientos éticos internacionales que aseguren la transparencia algorítmica, la reproducibilidad y la protección de los pacientes (Higuera Mosquera et al., 2025).

Los resultados sintetizados confirman que las CNN, en especial las arquitecturas híbridas y con mecanismos de atención, constituyen una herramienta de alta eficacia para mitigar los artefactos metálicos en TC. Su implementación clínica, sin embargo, requiere una integración progresiva, validada con evidencia multicéntrica y acompañada de políticas de gobernanza de datos y educación profesional continua que garanticen la seguridad, confiabilidad y beneficio diagnóstico para el paciente.

Conclusiones

El desarrollo de esta investigación permitió comprender de manera más profunda el papel que desempeñan los modelos U-Net y GAN en la reconstrucción y reducción de artefactos en TC, y cómo la inteligencia artificial se consolida como una herramienta transformadora dentro de la radiología moderna. A lo largo del proceso, se fortalecieron las habilidades de análisis crítico, selección y síntesis de literatura científica, lo que contribuyó a construir una visión más integral del impacto que las redes neuronales convolucionales pueden tener en la práctica clínica.

El análisis de los estudios revisados permitió reconocer que, si bien los modelos de aprendizaje profundo ofrecen resultados sobresalientes en la mejora de la calidad de imagen, su implementación real aún enfrenta limitaciones técnicas, éticas y de validación clínica. Este hallazgo nos llevó a reflexionar sobre la necesidad de que la innovación tecnológica esté acompañada de una evaluación rigurosa y responsable, orientada a la seguridad y al bienestar del paciente.

Desde una perspectiva personal y académica, esta investigación permitió reconocer que el avance científico requiere una lectura crítica de la evidencia, una constante actualización profesional y una disposición ética frente al uso de la inteligencia artificial en la salud.

Asimismo, permitió comprender que la calidad diagnóstica no depende únicamente del algoritmo, sino del criterio humano que lo interpreta y aplica de manera segura.

En conclusión, este estudio no solo aportó conocimientos teóricos sobre las arquitecturas U-Net y GAN, sino que también fortaleció nuestra capacidad para analizar, evaluar y proyectar nuevas líneas de investigación que integren la inteligencia artificial con la práctica radiológica, bajo principios de calidad, seguridad y humanización del diagnóstico por imágenes.

Referencias Bibliográficas

- Higuera Mosquera, D., et al. (2025). Análisis del uso y eficacia de las inteligencias artificiales aplicadas a la optimización de imágenes médicas.
<https://share.google/HpObI2Q1gn2PuJc1L>
- Kleber, C., et al. (2024). Advancements in supervised deep learning for metal artifact reduction in computed tomography: A systematic review.
- Ley 1581 de 2012 - Gestor Normativo . (s/f). Gobernador.co. Recuperado el 22 de septiembre de 2025, de <https://www.funcionpublica.gov.co/eva/gestornormativo/norma.php?i=49981>
- Ley 1915 de 2018. (12 de julio de 2018). Por la cual se modifica la Ley 23 de 1982 y se establecen disposiciones en materia de derecho de autor y derechos conexos. Diario Oficial de Colombia.
<https://www.funcionpublica.gov.co/eva/gestornormativo/norma.php?i=87419>
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., van Ginneken, B. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60–88. <https://doi.org/10.1016/j.media.2017.07.005>
- Lyu, Q., Wang, J., & Zhang, Y. (2023). Reduction of metal artifacts in X-ray CT images using a convolutional neural network. *Quantitative Imaging in Medicine and Surgery*, 13(4), 2320-2332. <https://pmc.ncbi.nlm.nih.gov/articles/PMC10177423/>
- Organización Mundial de la Salud (OMS). (2021). Ética y gobernanza de la inteligencia artificial para la salud: Orientación de la OMS. Organización Mundial de la Salud.
<https://iris.who.int/bitstream/handle/10665/350263/9789240037441-spa.pdf>
- Por medio del cual se regula l. (s/f). Congreso Visible. Recuperado el 22 de septiembre de 2025, de <https://congresovisible.uniandes.edu.co/proyectos-de-ley/ppor-medio-del-cual-se->

[regula-la-inteligencia-artificial-en-colombia-para-garantizar-su-desarrollo-etico-y-responsable-y-se-dictan-otras-disposiciones-regula-la-inteligencia-artificial/14540/](#)

Sánchez, F., & Gómez, L. (2025). Inteligencia artificial en tomografía computarizada: retos y perspectivas en la práctica clínica. Federación de Asociaciones de Bioingeniería Aplicada. <https://www.faba.edu.co/wp-content/uploads/2025/08/INTELIGENCIA-ARTIFICIAL-EN-TOMOGRAFIA-COMPUTARIZADA.pdf>

Sartori, P., Rozowykniat, M., Siviero, L., Barba, G., Peña, A., Mayol, N., Ortiz, A. (2015). Artefactos y artificios frecuentes en tomografía computada y resonancia magnética. Revista Argentina de Radiología. <https://doi.org/10.1016/j.rard.2015.04.005>

Scardigno, R. M., Brunetti, A., Marvulli, P. M., Carli, R., Dotoli, M., Bevilacqua, V., & Buongiorno, D. (2025). CALIMAR-GAN: An unpaired mask-guided attention network for metal artifact reduction in CT scans. Computerized Medical Imaging and Graphics, 123, 102565. <https://doi.org/10.1016/j.compmedimag.2025.102565>

Selles, M., Van Osch, J. A., Maas, M., Boomsma, M. F., & Wellenberg, R. H. (2024). Advances in metal artifact reduction in CT images: A review of traditional and novel metal artifact reduction techniques. European Journal of Radiology, 170, 111276. <https://doi.org/10.1016/j.ejrad.2023.111276>

Unión Europea. (2021). Reglamento del Parlamento Europeo y del Consejo por el que se establecen normas armonizadas en materia de inteligencia artificial (Ley de inteligencia artificial). Comisión Europea. <https://eur-lex.europa.eu/legal-content/ES/TXT/?uri=CELEX:52021PC0206>

Varghese, A. P., Naik, S., Asrar Up Haq Andrabi, S., Luharia, A., & Tivaskar, S. (2024). Enhancing Radiological Diagnosis: A Comprehensive Review of Image Quality

Assessment and Optimization Strategies. *Cureus*, 16(6), e63016.

<https://doi.org/10.7759/cureus.63016>

Xu, J., Wang, J., Liu, H., & Tang, Y. (2024). A comprehensive deep learning framework for CT image reconstruction and artifact reduction. *Computers in Biology and Medicine*, 173, 108112. <https://doi.org/10.1016/j.combiomed.2024.108112>

Yasui, K., Saito, Y., Ito, A. et al. (2023). Validación de la reconstrucción de imágenes de TC basada en aprendizaje profundo para la planificación del tratamiento. *Sci Rep* 13 , 15413 (2023). <https://doi.org/10.1038/s41598-023-42775-x>

Zhao, C., Tan, S., Lam, F., Liang, Z.-P. (2019). Artifact reduction in MR imaging via deep learning. *IEEE Transactions on Medical Imaging*, 38(12), 2694–2705. <https://doi.org/10.1109/TMI.2019.2911842>

Zhu, Y., Yang, Y., & Li, X. (2023). Artificial intelligence in CT: current status and future directions. *Quantitative Imaging in Medicine and Surgery*. <https://qims.amegroups.org/article/view/127003/html>