

**Reconstrucción Inteligente en TC: Eficiencia de CNN-MAR, AICE DLR y TrueFidelity en
la Eliminación de Artefactos**

Andrea Yosberly Méndez Gómez

Ángel Ramón Tarazona Lizcano

José Gregorio Medina Duque

Laura Daniela Rodríguez Cañas

Sergio Carmelo Villalba Suárez

Asesor

María Camila Dávila Castañeda

Universidad Nacional Abierta y a Distancia - UNAD

Escuela de Ciencias de la Salud ECISA

Tecnología en Radiología e Imágenes Diagnósticas

2025

Dedicatoria

Dedicamos este logro a nuestras familias, por su amor incondicional, apoyo constante y por ser el pilar que nos sostuvo en cada paso de este camino. A quienes ya no están físicamente, pero siguen vivos en nuestra memoria y corazón, guiándonos con su luz. A nuestros seres queridos, amigos y tutores, gracias por su paciencia, enseñanzas y motivación. Este logro es el reflejo del esfuerzo colectivo, de los sueños compartidos y de la fuerza que encontramos en el amor y la esperanza.

Agradecimientos

El presente trabajo investigativo, es el resultado del compromiso, la colaboración y la dedicación conjunta de un equipo de cinco estudiantes que, con entusiasmo y rigor académico, se asumió éste reto como parte del Diplomado de Profundización, para optar por el derecho a grado como Tecnólogos en Radiología e Imágenes Diagnósticas. Este logro, ha sido posible gracias a la bendición de Dios, quien con su infinita misericordia nos ha guiado, fortalecido y acompañado en cada paso de este camino. A Él le damos gracias, por darnos la sabiduría, la paciencia y el coraje para superar cada desafío; por iluminar el camino, también por brindarnos la paz en los momentos de incertidumbre.

Queremos expresar nuestro más sincero agradecimiento a la Universidad Nacional Abierta y a Distancia – UNAD, por brindarnos un espacio de formación integral, por su compromiso con la educación a distancia de calidad y por fomentar procesos investigativos que fortalecen nuestra disciplina.

De manera especial, agradecemos a nuestra tutora, María Camila Dávila Castañeda, por su guía constante, su acompañamiento cercano y su orientación precisa en cada etapa del proceso investigativo.

Extendemos también un reconocimiento a nuestras familias, cuyo apoyo incondicional ha sido esencial. Gracias por su paciencia, sus palabras de aliento, por comprender los tiempos de dedicación que este proceso exigía. Su amor y confianza han sido el motor que nos impulsó a continuar incluso en los momentos de mayor exigencia.

Este trabajo no solo representa una meta cumplida, sino también el reflejo del esfuerzo colectivo, el aprendizaje compartido y el deseo de contribuir al campo de la radiología. A todos los que formaron parte de este camino, nuestra gratitud más profunda.

Resumen

Esta investigación analiza la utilidad de las redes neuronales convolucionales (CNN) en la detección y corrección de artefactos en imágenes de tomografía computarizada (TC), evaluando su impacto en la calidad diagnóstica. Se realizó una revisión de la literatura científica publicada entre 2014 y 2024 en bases de datos como PubMed, Scopus e IEEE Xplore, priorizando estudios con evidencia empírica sobre algoritmos de Deep Learning aplicados a TC. Se exploraron tanto los tipos más frecuentes de artefactos como las estrategias de mitigación tradicionales y modernas.

Los hallazgos se centraron en el desempeño comparativo de los algoritmos CNN-MAR, AiCE DLR (Canon) y TrueFidelity (GE), analizados según reducción de ruido, preservación anatómica y detectabilidad de bajo contraste. CNN-MAR logró disminuir artefactos metálicos en más de un 40 %, mientras que AiCE y TrueFidelity mantuvieron o mejoraron la resolución en estudios de baja dosis, contribuyendo a una mayor seguridad para el paciente.

Los resultados evidencian el potencial de las CNN en la optimización de imágenes en TC, no obstante, su implementación clínica enfrenta desafíos técnicos, regulatorios y formativos que deben abordarse.

Palabras clave: Artefactos, tomografía, reconstrucción, algoritmo, aprendizaje.

Abstract

This research analyzes the usefulness of convolutional neural networks (CNNs) in the detection and correction of artifacts in computed tomography (CT) images, evaluating their impact on diagnostic quality. A review of the scientific literature published between 2014 and 2024 was conducted in databases such as PubMed, Scopus, and IEEE Xplore, prioritizing studies with empirical evidence on deep learning algorithms applied to CT. The most common types of artifacts and traditional and modern mitigation strategies were explored.

The findings focused on the comparative performance of the CNN-MAR, AiCE DLR (Canon), and TrueFidelity (GE) algorithms, analyzed based on noise reduction, anatomical preservation, and low-contrast detectability. CNN-MAR managed to reduce metal artifacts by more than 40%, while AiCE and TrueFidelity maintained or improved resolution in low-dose studies, contributing to greater patient safety.

The results demonstrate the potential of CNNs in CT image optimization; however, their clinical implementation faces technical, regulatory, and training challenges that must be addressed.

Keywords: Artifacts, tomography, reconstruction, algorithm, learning.

Tabla de Contenido

Introducción.....	10
Planteamiento del Problema.....	11
Justificación.....	13
Objetivos.....	15
Objetivo General.....	15
Objetivos Específicos.....	15
Marco Teórico.....	16
Formación de la Imagen.....	17
Artefactos en Tomografía Computarizada.....	20
Redes Neuronales Convolucionales (CNN) en Radiología.....	24
Aplicación en la Reducción de Artefactos en TC.....	25
Algoritmos de IA en TC.....	25
Limitaciones y Desafíos.....	29
Base Conceptual.....	30
Marco Metodológico.....	31
Revisión Documental y Selección de Fuentes.....	34
Criterios de Inclusión.....	35
Criterios de Exclusión.....	35
Marco Legal e Implicaciones Éticas.....	38
Protección de derechos patrimoniales.....	38
Derechos morales.....	38
Registro y Pruebas.....	39

Excepciones y Buenas Prácticas.....	39
Normativas Internacionales en Inteligencia Artificial en Salud.....	39
Consideraciones Bioéticas en el Uso de Inteligencia Artificial en Salud.....	40
Resultados.....	42
Desarrollo de la Revisión Bibliográfica.....	42
Análisis de la Literatura Revisada: Artefactos en Imágenes de TC.....	46
Discusión.....	47
Análisis de la Literatura Revisada: IA y Algoritmos de Reconstrucción en TC.....	48
Discusión.....	51
Conclusiones.....	53
Conclusiones Principales.....	53
Implicaciones Clínicas.....	53
Limitaciones del Estudio.....	53
Recomendaciones para Investigación Futura.....	53
Referencias Bibliográficas.....	55

Lista de Tablas

Tabla 1 <i>Términos y Definiciones Clave en Redes Neuronales y su Aplicación en Radiología</i>	30
Tabla 2 <i>Literatura Revisada Sobre Artefactos en Imágenes De TC</i>	36
Tabla 3 <i>Literatura Revisada Sobre Algoritmos de Reconstrucción y Uso de IA</i>	36
Tabla 4 <i>Literatura Revisada Sobre Artefactos en Imágenes de TC</i>	42
Tabla 5 <i>Literatura Revisada Sobre Algoritmos de Reconstrucción en TC</i>	43
Tabla 6 <i>Clasificación de Artefactos en Tomografía Computarizada y Estrategias de Mitigación</i>	47
Tabla 7 <i>Comparación Algoritmos de Reconstrucción por Inteligencia Artificial en TC y sus Principales Resultados</i>	50

Lista de figuras

Figura 1 <i>Matriz, Píxel y Vóxel</i>	17
Figura 2 <i>Tonalidades de Gris Según el Número de Bit de un Píxel</i>	18
Figura 3 <i>Algoritmo de Interpolación</i>	19
Figura 4 <i>Retroproyección Filtrada</i>	19
Figura 5 <i>Reconstrucción Iterativa</i>	20
Figura 6 <i>Artefacto Metálico en Imagen de TC</i>	21
Figura 7 <i>Artefacto por Movimiento en Imagen de TC</i>	21
Figura 8 <i>Artefacto por Absorción Desigual en Imagen de TC</i>	22
Figura 9 <i>Artefacto por Endurecimiento del Haz en Imagen de TC</i>	23
Figura 10 <i>Artefacto por Error en la Calibración en Equipo de TC</i>	23
Figura 11 <i>Algoritmo Aice(Advanced Intelligent Clear-IQ Engine de Canon)</i>	26
Figura 12 <i>Algoritmo Aice(Advanced Intelligent Clear-IQ Engine de Canon)</i>	27
Figura 13 <i>Algoritmo Truefidelity Para GSI de GE Healthcare</i>	28
Figura 14 <i>Algoritmo Truefidelity Para GSI de GE Healthcare</i>	29
Figura 15 <i>Resumen de las Fases que Estructuraron el Proceso Investigativo</i>	34

Introducción

La tomografía computarizada (TC) es una herramienta diagnóstica fundamental debido a su capacidad para generar imágenes de alta resolución con precisión anatómica. No obstante, hasta un 20 % de los estudios pueden verse afectados por artefactos, lo cual compromete la calidad de imagen, dificulta la interpretación clínica y puede derivar en errores diagnósticos o en la repetición innecesaria del examen.

Si bien las estrategias tradicionales, como la optimización de protocolos de adquisición, el mantenimiento del equipo y los algoritmos de reconstrucción iterativa (IR), han contribuido a mitigar estas distorsiones, aún persisten limitaciones significativas, especialmente en la estandarización de métricas objetivas y su validación en escenarios clínicos diversos.

En este escenario, las redes neuronales convolucionales (CNN) emergen como una solución innovadora para optimizar la reconstrucción de imágenes mediante el análisis avanzado de datos. La presente investigación tiene como propósito analizar la evidencia científica sobre su aplicación clínica, identificar ventajas comparativas y examinar los principales retos técnicos, éticos y regulatorios que implica su implementación.

Además de aportar al conocimiento sobre inteligencia artificial en imagenología, este estudio establece una base sólida para futuras investigaciones orientadas a mejorar la calidad de imagen en contextos hospitalarios complejos. Los hallazgos obtenidos pueden servir como referencia para evaluar nuevas técnicas de reconstrucción, comparar algoritmos existentes y orientar decisiones clínicas. Asimismo, al documentar el desempeño de tecnologías como AiCE, TrueFidelity y CNN-MAR, se abren posibilidades para optimizar los protocolos diagnósticos, reducir errores interpretativos y fortalecer la seguridad del paciente, contribuyendo de forma directa a la calidad y eficiencia en los servicios de radiología.

Planteamiento del Problema

La tomografía computarizada (TC), es una de las herramientas de diagnóstico por imágenes más utilizadas en la práctica clínica, debido a su alta resolución y capacidad para proporcionar información anatómica detallada. Sin embargo, la presencia de artefactos en las imágenes representa un desafío significativo, afectando hasta un 20% de los estudios de TC en general (Gjesteby et al., 2018). En exploraciones específicas, como en cabeza y cuello, los artefactos metálicos pueden comprometer hasta el 30% de las imágenes, mientras que, en imágenes torácicas y abdominales, los artefactos por movimiento del paciente pueden oscilar entre el 10% y el 25% (Rodríguez & Gómez, 2022). En hospitales de alta complejidad, el 25% de las exploraciones presentan artefactos metálicos, afectando la precisión diagnóstica y aumentando la probabilidad de errores clínicos (Zhang et al., 2023).

El impacto de los artefactos en TC no solo compromete la calidad de las imágenes, sino que también repercute en el ámbito clínico y económico. Asimismo, la obligación de repetir exámenes debido a imágenes de baja calidad genera un aumento de hasta el 25% en la carga asistencial y costos adicionales para los sistemas de salud (Gjesteby et al., 2018). En algunos centros hospitalarios, estos costos pueden superar el millón de dólares anuales (Iglesias López, 2023), evidenciando la magnitud del problema, instituciones como el Massachusetts General Hospital han implementado CNN revolucionado el procesamiento de imágenes médicas al reducir de un 40-50%, mejorando significativamente la calidad de las imágenes y la precisión diagnóstica (Park et al, 2024). De igual forma, la Universidad de Stanford ha desarrollado modelos especializados en la mitigación de artefactos por movimiento, obteniendo una mejora del 30% en la calidad de las imágenes. Sin embargo, la adopción de estas tecnologías enfrenta múltiples desafíos, como la inversión en hardware especializado, la falta de regulación

estandarizada para su implementación clínica y la exigencia de capacitación para los profesionales de la salud (Iglesias López, 2023).

A pesar de los avances recientes en inteligencia artificial aplicada a la imagenología, persiste una limitada disponibilidad de evidencia científica sobre la efectividad clínica, las limitaciones operativas y los desafíos asociados a su implementación. Esta carencia de datos, limita la integración sistemática en entornos hospitalarios. En este estudio, se aborda específicamente el uso de redes neuronales convolucionales (CNN), con énfasis en los algoritmos TrueFidelity™ (GE HealthCare) y AiCE (Advanced Intelligent Clear-IQ Engine, Canon Medical Systems), CNN-MAR, la revisión se centrará en publicaciones realizadas entre 2014 y 2024, con énfasis en experiencias clínicas desarrolladas en instituciones de alta complejidad.

Dado esto y las oportunidades de mejora tecnológica, surge la siguiente pregunta de investigación: ¿Qué evidencia científica existe sobre la aplicación de redes neuronales convolucionales (CNN) en la detección de artefactos en tomografía computarizada y cuáles son los principales desafíos para su implementación?

Esta investigación, se enfocará en un análisis cualitativo, basado en estudios previos, empleando una revisión narrativa de la literatura existente sobre el uso de redes neuronales en la reducción de artefactos en TC. Comprender estos aspectos, permitirá orientar futuros documentales, al mismo tiempo, facilitar una implementación más efectiva de tecnologías basadas en IA en entornos clínicos.

Justificación

La presente investigación es pertinente, porque permite consolidar el conocimiento existente sobre la detección de artefactos en tomografía computarizada (TC) mediante redes neuronales convolucionales (CNN). A través de un análisis cualitativo basado en estudios previos, se llevará a cabo una revisión narrativa de la literatura, para comparar los estudios más destacados en el uso de redes neuronales para la detección y mitigación de artefactos en TC.

A diferencia de otros estudios centrados en la implementación y prueba de modelos específicos como el de Serrano, 2023; esta investigación, busca analizar y evaluar críticamente los hallazgos disponibles. De esta manera, se identificaron tendencias, desafíos y oportunidades en el campo, proporcionando una visión integral sobre el estado actual del conocimiento.

La implementación efectiva de soluciones para reducir artefactos requiere personal capacitado y protocolos estandarizados, aspectos que aun presentan brechas en muchos entornos clínicos (Camargo et al., 2023). La intervención manual en la identificación y corrección de artefactos consume tiempo y recursos, además de depender del juicio humano, lo que puede generar controversia entre los radiólogos. En este contexto, el desarrollo de métodos automatizados representa una oportunidad significativa para optimizar el flujo de trabajo en los servicios de imágenes diagnósticas.

Desde una perspectiva regulatoria, la integración de inteligencia artificial (IA) en radiología, debe cumplir con normativas como las establecidas por la FDA (2021) y la MDR (2021), que garantizan su seguridad y eficacia clínica. En el ámbito académico, el uso de fuentes secundarias debe enmarcarse en la Ley 23 de 1982 y la regulación de la DNDA, que establecen lineamientos sobre derechos de autor, citación y uso ético de materiales protegidos. La

aplicación de estas normativas en la presente investigación garantiza el rigor en la documentación, al mismo tiempo, evita vulneraciones a la propiedad intelectual.

A nivel técnico, uno de los principales desafíos en el uso de CNN, es el sesgo presente en los conjuntos utilizados para el entrenamiento de los modelos, lo que puede comprometer la precisión en poblaciones no representadas (Zhang, Wang & Li, 2023). Además, la validación clínica de estas herramientas requiere exploración, para garantizar su aplicabilidad en diferentes entornos hospitalarios. Esta investigación analizó las estrategias propuestas para abordar estas limitaciones y su impacto en la calidad diagnóstica.

Desde una perspectiva económica, la implementación de IA en radiología conlleva costos iniciales elevados, asociados a la adquisición de hardware especializado y la capacitación del personal. Sin embargo, evidencia previa indican que su aplicación podría reducir la repetición de estudios hasta en un 30%, optimizando los recursos hospitalarios y disminuyendo la exposición innecesaria a la radiación (Serrano, 2023).

En este sentido, esta investigación ofrecerá una contribución significativa a la comunidad académica y profesional, en el campo de la radiología diagnóstica, especialmente a radiólogos, tecnólogos en imágenes diagnósticas e investigadores interesados en la inteligencia artificial aplicada a la salud. Al consolidar el conocimiento disponible sobre las redes neuronales específicas, como TrueFidelity™ de GE Healthcare y AiCE (Advanced Intelligent Clear-IQ Engine) de Canon Medical Systems, este estudio facilitará una comprensión más profunda de su aplicabilidad clínica, sus limitaciones y los retos asociados a su implementación.

Objetivos

Objetivo General

Analizar la evidencia científica relacionada con el uso de redes neuronales convolucionales (CNN) en la detección de artefactos en tomografía computarizada, e identificar los principales desafíos que afectan su implementación clínica.

Objetivos Específicos

Comparar literatura existente sobre la aplicación de redes neuronales convolucionales (CNN), para detección y corrección de artefactos en tomografía computarizada.

Identificar los tipos de artefactos en imágenes de tomografía computarizada que han sido detectados mediante redes neuronales convolucionales.

Describir los métodos y arquitecturas de CNN utilizados en estudios recientes para la detección y corrección de artefactos en imágenes médicas.

Analizar los principales desafíos que dificultan la implementación clínica de las CNN en la tomografía computarizada.

Marco Teórico

La tomografía computarizada (TC), es una de las técnicas de imagen médica más utilizadas debido a su capacidad, para proporcionar representaciones anatómicas detalladas. Sin embargo, la presencia de artefactos en las imágenes puede comprometer su calidad, dificultando el diagnóstico preciso, incrementando la frecuencia de exámenes adicionales y generando un alza en los costos operativos de los centros de salud. Se estima que estos artefactos, afectan aproximadamente el 20% de los estudios de TC, lo que representa un desafío significativo en la interpretación radiológica (Gjesteby et al., 2018; Rodríguez & Gómez, 2022).

Con el tiempo, se han desarrollado diversos métodos, para minimizar los artefactos en TC, incluyendo algoritmos de reconstrucción iterativa, mejoras en la captura de imágenes y técnicas de procesamiento digital. No obstante, la introducción de la IA ha abierto nuevas oportunidades, para mejorar la calidad de las imágenes y en particular, las CNN han demostrado gran potencial en la identificación y corrección automática de artefactos en TC. (Chen, Liu & Zhao, 2023).

A pesar de los avances logrados, la adopción de CNN en la eliminación de artefactos enfrenta desafíos considerables, como la falta de modelos de entrenamiento estandarizados, la exigencia de grandes volúmenes de datos etiquetados y la carencia de infraestructura adecuada en muchos centros médicos (Park, Kim & Lee, 2024).

Sin embargo, la mayoría de estas investigaciones se han enfocado en el desarrollo e implementación de modelos específicos, dejando un vacío en la sistematización y evaluación crítica de los hallazgos existentes.

Formación de la Imagen

El tubo de rayos x y los detectores, se encuentran rotando continuamente alrededor del paciente, y a su vez se emite radiación ionizante sobre el área anatómica de estudio. Por cada giro del tubo en 360° se emiten múltiples proyecciones, que forman los datos que serán transformados y procesados para obtener las imágenes diagnosticas. La formación de la imagen final se determina por: La dosis de radiación, atenuación, y localización del tubo.

Matriz

Hace referencia a la forma bidimensional en que se presenta la imagen, forman entre sí una rejilla compuesta de columnas y filas. (Figura 1)

Píxel

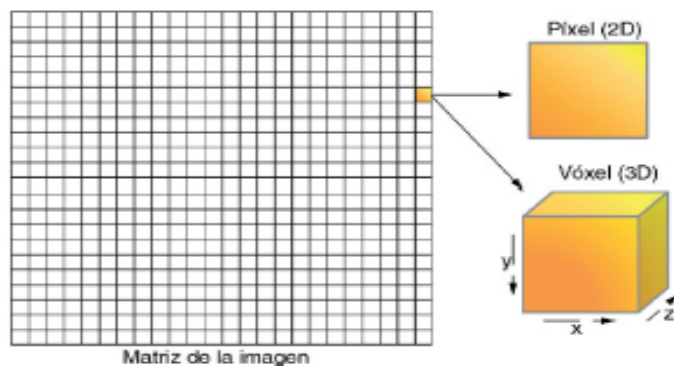
Compone la matriz, y cada uno de los píxeles tiene asignado un valor en unidades Hounsfield, el cual contiene densidades ópticas determinadas, como se observa en la figura 2.

Campo de Visión (FOV)

Es el área de estudio, limita el área de corte y puede ser reducido o ampliado según el área a estudiar.

Figura 1









Matriz, Píxel y Vóxel



Nota. (Costa, J; Soria, A. 2015)

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)

Reconstrucción de la Imagen

Es el proceso de los datos obtenidos de manera primaria (raw data), a los que se les asigna un valor en Unidades Hounsfield (UH) en cada uno de los píxeles que forman la matriz.

Reconstrucción de la Imagen Digital con Algoritmos

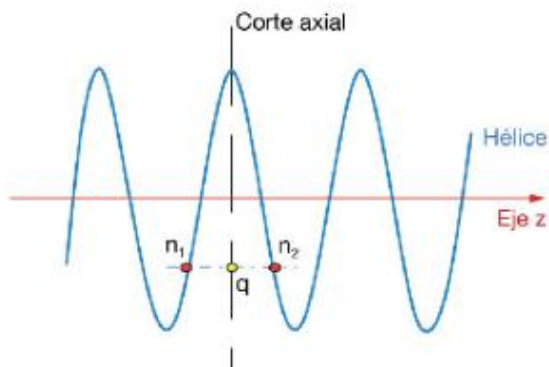
Los algoritmos en imágenes radiológicas, funcionan como transformadores de problemas en soluciones, es decir, convierten la información adquirida en los detectores en datos viables para creación y visualización de imágenes.

Algoritmos de Interpolación

Son datos matemáticos, que permiten la obtención de imágenes a partir de proyecciones que no han sido adquiridas en el plano inicial de la imagen (figura 3). En la interpolación se logra valorar datos no conocidos partiendo de los conocidos, con este tipo de algoritmos se realizan reconstrucciones transaxiales a partir de cortes oblicuos, por lo cual los resultados van a ser imágenes axiales de la misma calidad a las adquiridas en técnicas secuenciales.

Figura 3

Algoritmo de Interpolación




Nota. (Costa, J; Soria, A. 2015)

Retroproyección filtrada

Es una técnica de reconstrucción de imágenes de TC, basada en principios matemáticos, para que sean transformadas proyecciones de rayos x en imágenes bidimensionales. Esta técnica se centra en transformada inversa de Radón y el teorema del corte central de Fourier, lo que permite obtener reconstrucciones de las estructuras a estudiar, a partir de proyecciones obtenidas en diversos ángulos, este procedimiento utiliza filtros para suprimir ruido y por ende mejorar calidad de imagen. Sin embargo, presenta limitaciones, ya que al no presentar todas las proyecciones necesarias para las reconstrucciones se presenta una ampliación del ruido, y es susceptible a crear artefactos en imágenes con técnicas bajas de radiación. Su representación gráfica puede observarse en la figura 4.

Figura 4

Retroproyección Filtrada




Nota. (Costa, J; Soria, A. 2015)

Reconstrucción iterativa

Es una técnica avanzada, que tiene como objetivo ser alternativa a los métodos tradicionales y mejorar la calidad de las imágenes de TC, permitiendo la obtención de imágenes con menos ruido y nítidas usando dosis bajas de radiación. Es una secuencia basada en mediciones, ajustes matemáticos y suposiciones, es decir, la imagen va siendo corregida a través de comparación de datos desde ángulos diversos y cada proceso va perfeccionando la reconstrucción y así se consiguen reconstrucciones más acertadas. Como se observa en la figura 5.

Figura 5

Reconstrucción Iterativa



Nota. Comparación de imágenes TC antes (izquierda) y después (derecha) de aplicar innovaciones en hardware y algoritmos de reconstrucción. Tomado de Philips - Reconstrucción Iterativa de Modelo, (s. f.).

<https://www.philips.es/healthcare/product/HCNCTD449/reconstruccion-iterativa-de-modelo-imr-tecnologia-de-reconstruccion>


Artefactos en Tomografía Computarizada

Los artefactos en TC son distorsiones en las imágenes que pueden clasificarse según su origen (Azpeitia, Zegarra & Martín, 2016):

Artefactos Metálicos. Causados por implantes quirúrgicos, marcapasos u otros dispositivos metálicos que interfieren con la absorción de los rayos X. Su ejemplo se evidencia en la figura 6.

Figura 6

Artefacto Metálico en Imagen de TC




Nota. Plano abdominal superior, corte axial: se observa un objeto metálico ubicado en la pared abdominal anterior del paciente, correspondiente a la vía de administración parenteral, el cual produce artefactos tipo “rayos de sol” (señalados con cabezas de flecha). Tomado de Artefactos comunes en tomografía computarizada y resonancia magnética. Sartori et al. (2015).

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

Artefactos por Movimiento. Se producen cuando el paciente se mueve durante la exploración, generando imágenes borrosas o distorsionadas. (Véase figura 7)

Figura 7

Artefacto por Movimiento en Imagen de TC



Nota. TC de macizo craneofacial en ventana ósea, corte axial: se identifican imágenes borrosas repetidas tipo “fantasma”, producto de un artefacto por movimiento del paciente. Tomado de Artefactos comunes en tomografía computarizada y resonancia magnética. Sartori et al. (2015).

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

Artefactos por Absorción Desigual. Resultan de variaciones en la densidad de los tejidos, lo que altera la distribución de la radiación. (Ejemplo en la figura 8)

Figura 8

Artefacto por Absorción Desigual en Imagen de TC




Nota. TC de tórax, corte axial en ventana mediastino: se observan bandas alternas hipo e hiperdensas que dificultan la evaluación del hemitórax posterior (flechas), originadas por la imposibilidad del paciente de elevar los brazos. Tomado de Artefactos comunes en tomografía computarizada y resonancia magnética. Sartori et al. (2015).

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

Artefactos por Endurecimiento del Haz. Generado por absorción de fotones de baja energía de rayos en los tejidos (figura 9). Este artefacto es más común en hueso, ya que es de alta atenuación.

Figura 9

Artefacto por Endurecimiento del Haz en Imagen de TC




Nota. TC de cerebro, corte axial: se identifica un artefacto por endurecimiento del haz al atravesar el peñasco, visible como hiperdensidades en la región de los senos cavernosos (asterisco). Tomado de Artefactos comunes en tomografía computarizada y resonancia magnética. Sartori et al. (2015). <https://doi.org/10.1016/j.rard.2015.04.005>

Artefactos por Errores en la Calibración. Relacionados con fallos en la configuración del equipo de TC, afectando la precisión de las imágenes. (Véase figura 10)

Figura 10

Artefacto por Error en la Calibración en Equipo de TC



Nota. TC de cerebro, corte axial: se observan múltiples anillos concéntricos con apariencia de “rueda de carro” (flechas). Tomado de Artefactos comunes en tomografía computarizada y resonancia magnética. Sartori et al. (2015). <https://doi.org/10.1016/j.rard.2015.04.005>

Redes Neuronales Convolucionales (CNN) en Radiología

Las redes neuronales convolucionales (CNN), son un tipo de arquitectura de aprendizaje profundo especializada en el análisis de imágenes, que ha demostrado una notable eficacia en la detección de patrones y la mejora de la calidad de imágenes médicas (Zhang, Wang & Li, 2023). Su capacidad para reducir artefactos en tomografía computarizada (TC) radica en su estructura jerárquica, compuesta por capas convolucionales que extraen características progresivamente más complejas de una imagen.

Funcionamiento de las Capas Convolucionales

Las capas convolucionales son el núcleo de las CNN y su diseño permite identificar patrones jerárquicos en imágenes médicas mediante tres mecanismos clave: conexiones locales, filtros aprendibles y jerarquía de características.

Filtros y detección local. Cada capa convolucional aplica filtros (kernels) que escanean pequeñas regiones de la imagen (ej.: 3x3 píxeles). Estos filtros detectan características como bordes, texturas o formas mediante operaciones matemáticas (producto punto).

Mapas de características. Cada filtro genera un feature map que resalta la presencia de patrones específicos. Por ejemplo, en radiografías, un filtro podría activarse ante bordes óseos o sombras pulmonares.

Profundidad de capas. Las primeras capas identifican patrones simples (líneas, bordes), mientras que las capas profundas combinan estos elementos para reconocer estructuras complejas (ej.: nódulos pulmonares o fracturas).

Aprendizaje de Patrones Complejos

El entrenamiento de las CNN se basa en la retropropagación, ajustando los filtros para minimizar errores en las predicciones. Esto permite:

Jerarquía automática: Las capas iniciales aprenden a detectar bordes y contrastes (ej.: diferencias tejido óseo/blando), y las posteriores integran estos datos para identificar anomalías como tumores o edema.

Adaptabilidad: En radiodiagnóstico, las CNN ajustan sus filtros según el tipo de imagen (ej.: TC vs. resonancia magnética), optimizando la detección de patrones específicos para cada modalidad.

Aplicación en la reducción de artefactos en TC

Diversos estudios han explorado el uso de CNN para mitigar artefactos en TC, destacándose especialmente aquellas arquitecturas entrenadas con imágenes emparejadas (con y sin artefactos). Por ejemplo, arquitecturas tipo U-Net han sido ampliamente empleadas por su capacidad para preservar detalles anatómicos mientras eliminan distorsiones metálicas (Zhang et al., 2018; Liu et al., 2020). Investigaciones como la de Lin et al. (2019) aplicaron CNN supervisadas, para mejorar imágenes afectadas por implantes dentales, reportando una mejora significativa en la relación señal-ruido (SNR). Asimismo, modelos híbridos que integran redes profundas con reconstrucción iterativa han mostrado ventajas adicionales en cuanto a la reducción del ruido estructurado sin pérdida de contraste (Chen et al., 2021). Estas evidencias coinciden en que las CNN superan a los métodos tradicionales en calidad de imagen, aunque todavía persisten retos en la generalización de resultados y la validación en entornos clínicos reales.

Algoritmos de IA en TC

AiCE (Advanced Intelligent Clear-IQ Engine de Canon).

Es una tecnología de reconstrucción de imágenes que se encuentra basado en redes de aprendizaje profundo, figura 11 muestra reconstrucción con el algoritmo, lo cual permite diferenciar entre señal y ruido en imágenes de TC, así mismo:

Mejora la calidad de la imagen sin aumentar la dosis de radiación.

Preserva alta resolución espacial.

Reduce el ruido en las imágenes.

En cuanto a la reducción de artefactos, supera limitaciones de técnicas convencionales, como lo es la reconstrucción iterativa ya que esta se basa en tiempos de procesamiento largos y generan texturas o apariencias que hacen perder la naturalidad de la imagen.

Permite, además, disminuir artefactos metálicos y de movimiento. Por lo que facilita mejoras en diagnósticos en estudios tomográficos de cerebro, sistema musculoesquelético, corazón, y pulmón. La figura 12 muestra la correlación entre las imágenes originales y las procesadas con el algoritmo AiCE, resaltando una mejora sustancial en la nitidez y reducción de artefactos.

Figura 11

Algoritmo AiCE(Advanced Intelligent Clear-IQ Engine de Canon)




Nota. AiCE proporciona una mejora en la resolución anatómica en diversas áreas del cuerpo.

Tomado de Canon Medical Systems Europe. (2024).

<https://es.medical.canon/products/computed-tomography/advanced-intelligent-clear-iq-engine-aice/>

Figura 12

Algoritmo AiCE (Advanced Intelligent Clear-IQ Engine de Canon)



Nota. AiCE proporciona una mejora en la resolución anatómica en diversas áreas del cuerpo.

Tomado de Canon Medical Systems Europe. (2024).

<https://es.medical.canon/products/computed-tomography/advanced-intelligent-clear-iq-engine-aice/>

TrueFidelity para GSI de GE HealthCare.

Es una tecnología innovadora creada a partir de algoritmos de aprendizaje profundo con la finalidad de mejorar calidad en las imágenes obtenidas, la cual permite mejorar la detección de lesiones al aumentar el contraste entre los tejidos, y se da una reducción significativa del ruido en imágenes de baja energía. Además, va de la mano con técnicas de reducción de artefactos metálicos para revelar estructuras anatómicas y patológicas ocultas. Así mismo, es usada en aplicaciones clínicas específicas como:

Oncología: Especialmente usado en órganos abdominales, ya que mejora el contraste y optimiza imágenes permitiendo detectar tumores de manera rápida.

Imágenes vasculares: Mejora la visualización de vasos y flujo sanguíneo, por lo que facilita diagnosticar trombos y defectos de perfusión (figura 14).

En pacientes con obesidad mórbida: Permite mantener la calidad de la imagen sin comprometer el campo de visión en pacientes con >40 IMC.

Esta tecnología es una herramienta que, por medio del uso de aprendizaje profundo, permite mejorar la calidad de las imágenes de TC espectral, reduce los artefactos y por ende amplía las posibilidades de diagnósticos precisos. En la Figura 13 se compara TrueFidelity™ con métodos convencionales, evidenciando los avances en calidad de imagen mediante redes neuronales profundas.

Figura 13


Algoritmo TrueFidelity para GSI de GE HealthCare



Nota. Imágenes con TrueFidelity en paciente con IMC 62, con notable calidad y reducción de ruido. Tomado de TrueFidelity CT, (s. f.). <https://www.gehealthcare.com.au/products/computed-tomography/truefidelity>

Figura 14

Algoritmo TrueFidelity para GSI de GE HealthCare



Nota La reducción de ruido en imágenes cardíacas con deep learning permite disminuir el kVp sin comprometer la calidad de imagen. Tomado de TrueFidelity CT, (s. f.).

<https://www.gehealthcare.com.au/products/computed-tomography/truefidelity>

Limitaciones y desafíos

Si bien estudios como los de IBM y PubMed resaltan la eficacia de las CNN en tareas como clasificación de nódulos y mejora de resolución, otros como PMC advierten sobre desafíos clave:

Dependencia de Datos. Se requieren grandes volúmenes de imágenes anotadas para entrenar modelos robustos, algo crítico en entornos con recursos limitados.

Resolución vs. Rendimiento. Investigaciones como la de RSNA demuestran que aumentar la resolución de imágenes mejora la detección de hallazgos pequeños (ejemplo: nódulos de 3 cm), pero no necesariamente de anomalías difusas (ejemplo: enfisema), lo que exige equilibrar calidad y coste computacional.

Estos hallazgos, sugieren que el uso de CNN, no solo optimiza los recursos hospitalarios, sino que también reduce la exposición innecesaria a la radiación, reforzando su importancia en la seguridad del paciente y la eficiencia del diagnóstico por imágenes.

Base Conceptual

Tabla 1

Términos y definiciones clave en redes neuronales y su aplicación en radiología

Término	Definición	Fuente
Machine Learning en radiología	Uso de algoritmos de aprendizaje automático para optimizar la adquisición y análisis de imágenes médicas.	Iglesias López (2023)
Validación de modelos de IA	Procedimiento de evaluación de modelos de inteligencia artificial antes de su implementación clínica, garantizando su precisión y cumplimiento con los estándares de calidad.	PMC (2023)
Capas convolucionales	Funcionamiento basado en filtros que detectan patrones locales en imágenes, generando mapas de características mediante operaciones matemáticas.	Barcelona, T et al (s.f)
Retropropagación	Algoritmo de entrenamiento para minimizar errores mediante ajuste iterativo de pesos en redes neuronales.	Sabottke,C et al (2020)
Sobreajuste	Ocurre cuando un modelo memoriza los detalles específicos del conjunto de datos utilizados durante su fase de entrenamiento, en lugar de identificar patrones generales, lo que reduce su capacidad de rendimiento al aplicarse a datos nuevos.	Sabottke,C et al (2020)
Clasificación de imágenes radiológicas	Uso de arquitecturas de redes neuronales convolucionales (CNN) para categorizar imágenes mediante capas convolucionales que extraen características jerárquicas.	Sabottke,C et al (2020)
Validación cruzada de modelos de IA	División de datasets en subconjuntos de entrenamiento y prueba para evaluar capacidad de generalización de modelos.	Sabottke,C et al (2020)

Nota. La tabla presenta los principales conceptos utilizados, junto con sus definiciones y fuentes correspondientes.

Marco Metodológico

Esta investigación se enfocará en un análisis cualitativo basados en estudios previos, empleando una revisión narrativa de la literatura existente, sobre el uso de redes neuronales en la reducción de artefactos en TC. Comprender estos aspectos permitirá orientar futuras investigaciones y facilitar una implementación más efectiva de tecnologías basadas en IA en entornos clínicos. A continuación, se describen las fases que estructuraron el proceso investigativo:

Fase I. Revisión bibliográfica y Análisis del tema de investigación.

Durante esta fase se identificó la pertinencia de abordar, desde la evidencia científica, el uso de redes neuronales convolucionales como una alternativa que surge para mejorar la calidad de imagen en TC. Esta perspectiva orientó el desarrollo del protocolo de búsqueda documental, el cual se aplicó a bases de datos científicas reconocidas como PubMed, Scopus, ScienceDirect, IEEE Xplore, SpringerLink y Google Scholar. Se establecieron criterios de búsqueda que incluyeron filtros por año de publicación (2014-2024), idioma (español e inglés) y disponibilidad de texto completo. Asimismo, se utilizaron descriptores específicos como convolutional neural networks, computed tomography artifacts, Deep Learning in radiology e image quality enhancement.

Se optó por un diseño de investigación cualitativo con apoyo en datos cuantitativos, interpretados desde una perspectiva crítica y no estadística.

Fase II. Desarrollo del marco teórico, conceptual y normativo

Durante esta fase se elaboraron los distintos marcos que sustentan teóricamente la investigación. Se construyó el marco teórico a partir de la revisión de estudios científicos recientes que abordan la aplicación de redes neuronales convolucionales (CNN) en la tomografía

computarizada, así como su rol en la detección y corrección de artefactos. Este análisis permitió identificar avances relevantes, enfoques metodológicos utilizados en otras investigaciones y vacíos de conocimiento que justifican la pertinencia del presente estudio, se abordaron las implicaciones clínicas y operativas que tiene la presencia de estos artefactos en distintos entornos hospitalarios.

En el marco conceptual, se definieron los términos clave que guían la investigación, tales como inteligencia artificial, redes neuronales convolucionales, artefactos en tomografía computarizada y aprendizaje profundo. Esta parte facilitó la comprensión del lenguaje técnico y especializado necesario para el abordaje del tema.

Finalmente, se integró el marco normativo y ético, en el cual se tuvo en cuenta la legislación vigente sobre derechos de autor en Colombia, específicamente la Ley 23 de 1982 y la Ley 1915 de 2018, así como los lineamientos establecidos por la Dirección Nacional de Derechos de Autor (DNDA). Este componente normativo fue clave para garantizar el uso responsable y ético de las fuentes secundarias consultadas, asegurando el respeto por los derechos patrimoniales y morales de los autores.

Fase III. Desarrollo de la metodología, análisis de la literatura y formulación de objetivos

Durante esta fase, se consolidó el enfoque metodológico de la investigación y se profundizó en la recopilación, organización y análisis de la literatura científica relacionada con el uso de CNN en la detección de artefactos en TC.

El análisis de la información se desarrolló mediante un enfoque inductivo, lo que permitió que las categorías analíticas surgieran de forma natural durante la revisión de la literatura. Para estructurar el proceso, se organizó una tabla con el tipo de literatura, el título y un resumen de cada fuente, lo cual facilitó la selección de estudios relevantes enfocados en redes

neuronales convolucionales. Esta estrategia aportó claridad metodológica y transparencia al proceso interpretativo. Aunque no se utilizaron herramientas digitales como gestores bibliográficos o software de análisis cualitativo, se implementaron procedimientos manuales rigurosos que garantizaron la coherencia, el orden y la trazabilidad en el tratamiento de los datos. La revisión documental también permitió, como parte fundamental de esta fase, formular los objetivos de la investigación, los cuales orientan el desarrollo del estudio y permiten dar respuesta al planteamiento del problema.

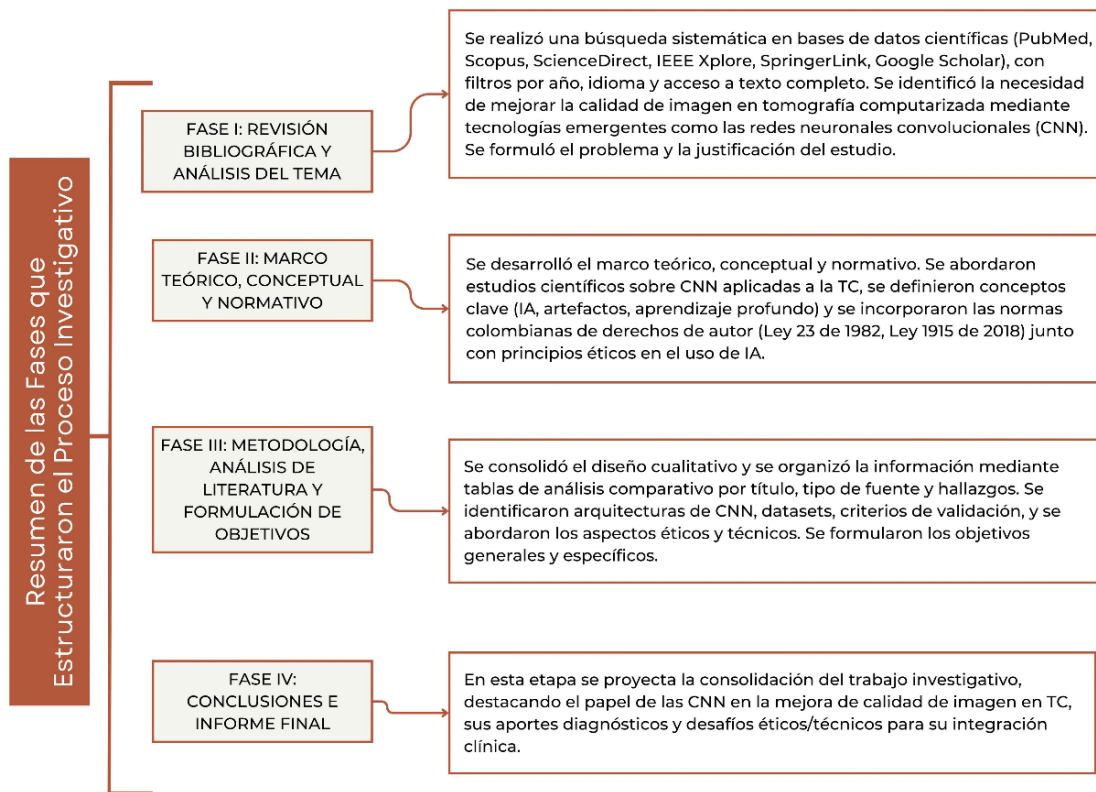
Fase IV. Elaboración de conclusiones y consolidación del informe final

En esta etapa final, se tiene previsto consolidar el trabajo investigativo y reflexionar críticamente sobre el papel que desempeñan las redes neuronales convolucionales en la mejora de la calidad de imagen en TC. Las conclusiones estarán orientadas a responder directamente el planteamiento del problema, destacando las evidencias científicas encontradas, los aportes más significativos y los desafíos actuales que enfrentan estas tecnologías para su integración en la práctica clínica.

A continuación, se presenta un resumen de las fases que estructuraron el proceso metodológico. (Figura 15)

Figura 15

Resumen de las fases que estructuraron el proceso investigativo



Nota. Autoría propia

Revisión documental y selección de fuentes

En esta etapa metodológica se llevó a cabo una revisión sistemática de la literatura científica relevante para el estudio, enfocada en dos ejes temáticos principales:

Los artefactos en imágenes de tomografía computarizada (TC).

Los algoritmos de reconstrucción, en particular aquellos basados en inteligencia artificial (IA) y redes neuronales convolucionales (CNN).

La búsqueda se realizó en bases de datos académicas reconocidas como PubMed, Scopus, ScienceDirect, IEEE Xplore y Google Scholar, utilizando descriptores específicos en inglés y español.

Para garantizar la calidad y pertinencia de las fuentes consultadas, se aplicaron criterios de inclusión y exclusión previamente definidos. Posteriormente, los estudios seleccionados fueron organizados en tablas, las cuales resumen el tipo de literatura, el contenido y su relevancia para el desarrollo del estudio. Lo que permitió identificar tendencias actuales, enfoques metodológicos y vacíos investigativos relacionados con la reducción de artefactos en TC mediante tecnologías emergentes.

Criterios de Inclusión

Publicaciones entre 2014 y 2024.

Documentos de texto completo en español e inglés disponibles en la web.

Literatura científica (tesis, trabajos investigativos y artículos)

Estudios que abordan información relevante sobre artefactos en imágenes de tomografía computarizada y tecnologías para su disminución y eliminación.

Investigaciones que incluyan soluciones a presencia de artefactos basadas en inteligencia artificial (IA), algoritmos o redes neuronales convolucionales (CNN).

Fuentes que analicen el impacto clínico, técnico o ético de los artefactos en TC.

Criterios de Exclusión

Documentos sin respaldo científico o sin acceso completo.

Publicaciones enfocadas en otras técnicas de imagen (Resonancia magnética, o rayos x) que no aplican en TC.

Investigaciones que no abordan estrategias de reconstrucción o mitigación.

Literatura no científica (blogs, columnas de opinión, investigaciones sin referencias metodológicas)

Tabla 2*Literatura Revisada sobre Artefactos en Imágenes de TC*

Título	Tipo de literatura	Cumple criterios	Justificación de inclusión
Artefactos y artificios frecuentes en tomografía computada y resonancia magnética	Artículo de revista científica	X	Analiza los tipos de artefactos más comunes en TC, sus causas y medidas correctivas. Fuente actual, revisada por pares.
Evaluación de artefactos en imágenes radiográficas digitales (CR vs DR)	Tesis de grado	X	Revisión técnica y práctica del impacto del personal y el equipo en la generación de artefactos.
Artefactos que afectan la calidad en la imagen de tomografía computarizada	Trabajo investigativo	X	Se enfoca en las causas clínicas y técnicas de artefactos y propone estrategias de mejora.

Nota. Descripción resumida de la literatura incluida y revisada sobre artefactos en imágenes de TC.

Tabla 3*Literatura Revisada sobre Algoritmos de Reconstrucción y Uso de IA*

Título	Tipo de literatura	Cumple criterios	Justificación de inclusión
Optimización basada en algoritmos de IA para la mejora de la calidad de imagen en TC de cráneo	Trabajo de investigación (UNAD)	X	Evalúa algoritmos modernos como AiCE y TrueFidelity aplicados a la reducción de artefactos.
Optimización basada en algoritmos de IA para la mejora de imagen en TC	Tesis de grado	X	Describe el papel de los algoritmos de reconstrucción en la mejora de calidad diagnóstica, especialmente en dosis bajas.
Aplicación para la reducción de artefactos metálicos en TC	Serie científica UCI	X	Propone métodos innovadores como ISMAR para mitigar artefactos metálicos mediante software propio.
Impacto de la Inteligencia Artificial en la Radiología	Artículo de revista cubana	X	Analiza el valor agregado de la IA en radiología desde un enfoque clínico y práctico.
Reduction of metal artifacts in X-ray CT images using a convolutional neural network (CNN-MAR)	Artículo de congreso (SPIE, 2017)	X	Presenta un enfoque robusto con redes neuronales convolucionales para la corrección de artefactos metálicos, con metodología clara.

Título	Tipo de literatura	Cumple criterios	Justificación de inclusión
AiCE Deep Learning Reconstruction: Bringing the power of Ultra-High Resolution CT to routine imaging. Canon Medical Systems Corporation	Literatura Gris Técnica	X	Este informe técnico proporciona una descripción detallada del funcionamiento y los fundamentos del algoritmo AiCE basado en Deep Learning, ofreciendo información directa del desarrollador sobre su diseño, arquitectura y beneficios clínicos.
A new era of image reconstruction: TrueFidelity Technical White Paper on Deep Learning Image Reconstruction. GE Healthcare.	Literatura Científica	X	Explica el desarrollo y la aplicación clínica del algoritmo TrueFidelity en imágenes espectrales, incluyendo evaluaciones de rendimiento, estudios en fantomas y casos clínicos reales.

Nota. Descripción resumida de la literatura incluida y revisada sobre algoritmos de reconstrucción y uso de IA en imágenes de TC.

Marco Legal e Implicaciones Éticas

En el contexto de la investigación académica, el uso de fuentes secundarias debe estar enmarcado en normativas que regulan los derechos de autor. En Colombia, la Ley 23 de 1982 y la Dirección Nacional de Derechos de Autor (DNDA) establecen lineamientos específicos sobre la citación, el uso de imágenes y la reproducción de textos ajenos. La aplicación de estas normativas en el presente trabajo se centra en garantizar la legalidad y la ética en el uso de materiales protegidos por derechos de autor.

Protección de derechos patrimoniales

La Ley 23 de 1982, otorga a los autores derechos exclusivos sobre la reproducción, distribución y comunicación pública de sus obras (Art. 12). En este contexto, el trabajo académico debe considerar:

La citación de textos e imágenes debe realizarse dentro de las limitaciones legales, especialmente en usos educativos y de investigación sin fines comerciales.

La reproducción parcial de una obra debe respetar el principio de proporcionalidad y no afectar su explotación económica.

El uso de imágenes o gráficos requiere autorización explícita si su finalidad trasciende el ámbito educativo o crítico.

La DNDA supervisa el cumplimiento de estas disposiciones y proporciona directrices sobre casos específicos.

Derechos morales

El Art. 30 de la Ley 23 de 1982 protege el derecho a la integridad de la obra y el reconocimiento del autor. En la elaboración del presente trabajo, se aplicarán las siguientes consideraciones:

Toda citación debe incluir una referencia precisa, evitando alteraciones que desvirtúen el mensaje original.

Las fuentes secundarias (artículos, libros, imágenes) serán debidamente citadas bajo normas APA 7

Se evitará el plagio, garantizando la originalidad del trabajo y respetando la presunción de titularidad del autor (Art. 10, Ley 1915 de 2018).

Registro y pruebas

Aunque el registro ante la DNDA no es obligatorio para la protección de derechos de autor, sí representa un medio probatorio en casos de disputa legal. En este sentido:

Se documentarán todas las fuentes utilizadas con referencias completas y precisas.

Se recurrirá a repositorios institucionales o plataformas académicas para garantizar el acceso legal a los materiales empleados.

Excepciones y buenas prácticas

La Ley 23 de 1982 permite ciertas excepciones al derecho de autor en entornos académicos, siempre que no haya ánimo de lucro. Para cumplir con estas disposiciones:

Se citarán fragmentos con fines críticos o analíticos.

Se evitará la reproducción integral de obras protegidas, como capítulos completos de libros.

Normativas Internacionales en Inteligencia Artificial en Salud

En el contexto del uso de inteligencia artificial (IA) en el ámbito de la salud, especialmente en aplicaciones tan sensibles como la tomografía computarizada, es fundamental considerar los marcos normativos internacionales que orientan su desarrollo ético, seguro y centrado en el bienestar del paciente.

La Organización Mundial de la Salud (OMS) publicó en 2021 el informe *Ética y gobernanza de la inteligencia artificial para la salud*, donde establece seis principios rectores para el uso de IA en el sector salud: protección de la autonomía humana, promoción del bienestar y la seguridad, transparencia, responsabilidad, inclusión y sostenibilidad. Este marco subraya la importancia de que las tecnologías basadas en IA no reemplacen el juicio clínico humano, sino que lo complementen, asegurando siempre la equidad en el acceso y el respeto por los derechos fundamentales de los pacientes.

Por su parte, la Unión Europea ha desarrollado una propuesta de reglamento conocido como la Ley de Inteligencia Artificial (IA), en la cual se clasifican los sistemas de IA según su nivel de riesgo. Las aplicaciones en salud, como los algoritmos utilizados para el diagnóstico por imágenes, se consideran de alto riesgo y, por tanto, están sujetas a requisitos rigurosos de calidad, trazabilidad, documentación técnica y supervisión humana. Este enfoque busca proteger a los usuarios frente a posibles errores diagnósticos o distorsiones presentes en la información de referencia usada para entrenar la red neuronal, garantizando así la fiabilidad y la transparencia del sistema.

Consideraciones Bioéticas en el Uso de Inteligencia Artificial en Salud

El desarrollo y aplicación de tecnologías de inteligencia artificial (IA), en el campo de la salud, como las redes neuronales convolucionales para la mejora de imágenes tomográficas, plantea desafíos bioéticos que deben ser abordados con responsabilidad. En este contexto, la bioética actúa como un eje fundamental para orientar la investigación y el uso clínico de estas herramientas, priorizando la dignidad humana, la autonomía del paciente y la equidad en el acceso a los beneficios tecnológicos.

Uno de los principios clave es la beneficencia, que implica asegurar que la aplicación de IA contribuya efectivamente a mejorar la calidad diagnóstica y aminorar los errores médicos. La no maleficencia, por su parte, exige que estas herramientas no generen daño, lo cual cobra especial relevancia en la validación de algoritmos, la prevención de sesgos y la adecuada interpretación de los resultados por parte de profesionales capacitados.

Asimismo, el principio de autonomía requiere que los pacientes sean informados adecuadamente sobre el uso de tecnologías de IA en su atención médica, promoviendo la toma de decisiones libres y conscientes. Finalmente, el principio de justicia exige que el acceso a estos avances tecnológicos sea equitativo, evitando su concentración en sistemas de salud privilegiados y fomentando su disponibilidad en contextos de alta complejidad donde más se necesitan.

Resultados

Desarrollo de la Revisión Bibliográfica

Tabla 4

Literatura Revisada sobre Artefactos en Imágenes de TC

Titulo	Tipo de Literatura	Resumen
Artefactos y artificios frecuentes en tomografía computada y resonancia magnética.	Artículo de la Revista Argentina de Radiología	El artículo analiza los principales artefactos en estudios de TC, los cuales generan cambios errores diagnósticos, y por ende causa errores de interpretación en las imágenes. Las causas más comunes de distorsiones son materiales metálicos, movimiento del paciente, errores en detectores o técnicas mal empleadas, variaciones en densidades tisulares y factores externos como humedad o polvo. Estos artefactos, pueden observarse como imágenes deformadas o con líneas, y pueden ser minimizados con técnicas adecuadas, preparación correcta del paciente, y tecnología actualizada, con la finalidad de mejorar la calidad diagnóstica de las imágenes obtenidas y la seguridad del paciente.
Evaluación de artefactos en imágenes radiográficas digitales procedentes de equipo radiológico computarizado vs equipo digital directo	Tesis de grado/Universidad Nacional Federico Villareal	El trabajo investigativo demuestra que minimizar los artefactos en las imágenes diagnósticas no depende únicamente de la tecnología que se emplee, sino de la atención, el conocimiento y las prácticas del personal de salud involucrado en el proceso. Se encuentra la comparación de equipos digitales directos (DR) y equipos computarizados (CR), además, se identifican las causas de los artefactos y se proponen acciones como: capacitación correcta del tecnólogo, indicaciones adecuadas al paciente, mantenimiento preventivo del hardware, limpieza periódica al equipo, configuración correcta del software y un seguimiento administrativo, esto con la finalidad de corregir errores y optimizar los recursos.
Artefactos que afectan la calidad en la imagen de tomografía computarizada	Trabajo investigativo.	Se estudia la relación entre diversos artefactos y factores físicos del paciente como el sobrepeso, así como el uso de dispositivos médicos para mejorar la calidad de las imágenes de TC. Además, se destaca las implicaciones clínicas de estos elementos en la precisión diagnóstica, así como los riesgos para la salud del paciente. Los hallazgos obtenidos recomiendan implementar estrategias como algoritmos de reconstrucción iterativa que van de la mano con mantenimiento adecuado de los equipos y la preparación adecuada del paciente con el fin

de mejorar la calidad de las imágenes, disminuir costos al repetir estudios y establecer estándares radiológicos sostenibles y eficaces.

Nota. Descripción resumida de la literatura revisada sobre artefactos en imágenes de TC.

Tabla 5

Literatura Revisada sobre Algoritmos de Reconstrucción en TC

Titulo	Tipo de Literatura	Resumen
Optimización basada en algoritmos de IA para la mejora de la calidad de imagen en tomografía computarizada de cráneo: eficiencia y reducción de ruido	Trabajo de investigación (UNAD)	Esta propuesta analiza los avances tecnológicos, principalmente los algoritmos de reconstrucción basados en IA, en la transformación de la calidad de imágenes en TC de cráneo. Habitualmente, se usan algoritmos como retroproyección filtrada (FBP) y reconstrucción iterativa (IR), para evitar las barreras ocasionadas por estos métodos, el estudio analiza principalmente algoritmos como AiCE de Canon y TrueFidelity de GE, ya que estos han demostrado con el uso de CNN la capacidad de reducir ruido y artefactos, sin que se vea afectada la resolución espacial y el contraste de los tejidos blandos, logrando así obtener imágenes viables para el diagnóstico clínico incluso aplicando técnicas bajas de radiación.
Optimización basada en algoritmos de IA para la mejora de la calidad de imagen en tomografía computarizada.	Tesis de grado.	La TC proporciona imágenes específicas de las estructuras anatómicas del cuerpo humano realizando múltiples cortes transversales, para ello se utilizan técnicas basadas en reconstrucción que se encargan de procesar los datos adquiridos en la matriz detectora. Las imágenes obtenidas son vistas en la escala de Hounsfield, la cual muestra la densidad de los tejidos y estructuras a estudiar (en escala de grises). Aunque los métodos son avanzados y se encuentran en mejora continua para reducir artefactos y ruido, la calidad de las imágenes y su utilidad en el diagnóstico se puede afectar por factores diversos entre ellos: El uso de dosis bajas de radiación, lo que ha mostrado efectos variables en la calidad de la imagen y su textura.
Aplicación para la reducción de artefactos metálicos en imágenes de Tomografía	Serie Científica de la Universidad de las Ciencias Informáticas	El presente artículo, muestra una propuesta concreta para enfrentar uno de los problemas más complejos de la TC, los artefactos metálicos. Por medio de algoritmos como ISMAR, GISMAR, MIFMAR e IMIFMAR, los que actúan en imágenes que ya han sido procesadas o reconstruidas por medio de DICOM, con técnicas de filtrado morfológico, suavizado e interpolación. Se

Computarizada (TC)		desarrolló un software en C++ con Qt y OpenCV, lo que permite que médicos y técnicos puedan usarlo de forma intuitiva, con la finalidad de mejorar la calidad diagnóstica y así adaptarlos a diferentes requerimientos clínicas.
Impacto de la Inteligencia Artificial en la Radiología	Revista Cubana de Informática Médica	El autor durante su formación en Imagenología y Radio física Médica, se percató que los recursos informáticos no se estaban utilizando de manera óptima, lo que ocasionaba demoras y un uso ineficaz de la información. Lo cual lo llevó a cuestionarse sobre cómo la IA podría elevar la calidad de los servicios de imagenología, proponiendo así analizar su impacto en radiología y su implementación en hospitales con la finalidad de optimizar el flujo de trabajo y la atención al paciente.
Reduction of metal artifacts in x-ray CT images using a convolutional neural network.	SPIE Medical Imaging Conference (2017)	Este estudio aborda artefactos en TC, causados por materiales metálicos implantados en el cuerpo del paciente, estos objetos generan distorsiones significativas en la imagen, que dificultan la interpretación clínica. Por lo que se propone soluciones a través de enfoques modernos basados en CNN, conocido como CNN-MAR. Se crean bases de datos simuladas con diferentes tipos de metales y se aplican métodos de corrección tradicionales (LI y BHC) como insumos para entrenar la CNN. Estas redes son entrenadas para diferenciar entre distorsiones y datos viables, así como también en reconstrucción de imágenes usando como complemento con procesamiento tisular para la eliminación de restos de artefactos, además se utiliza retroproyección para mejorar la visualización de las estructuras anatómicas, la reconstrucción final muestra imágenes con artefactos reducidos y estructuras anatómicas bien conservadas, incluso en áreas adyacentes a los implantes metálicos.
AiCE Deep Learning Reconstruction: Bringing the power of Ultra-High Resolution CT to routine imaging. Canon Medical Systems Corporation	Literatura gris técnica.	Su finalidad es transformar los datos adquiridos en imágenes de TC en imágenes de alta calidad, logrando superar las limitaciones dadas en métodos tradicionales por medio de una reconstrucción precisa, realista y eficiente. Su principal fortaleza es la reducción significativa de ruido sin afectar la resolución espacial y la textura, esto mejora principalmente la visualización de estructuras anatómicas de bajo contraste, fundamentales en la práctica clínica. AiCE DLR representa una solución integral que combina algoritmos avanzados de Deep Learning con hardware de última generación. Mejora la calidad diagnóstica mediante la reducción del ruido y la preservación de detalles finos,

<p>A new era of image reconstruction: TrueFidelity Technical White Paper on Deep Learning Image Reconstruction. GE Healthcare.</p>	<p>Literatura gris científica.</p>	<p>al tiempo que optimiza la eficiencia operativa. Este enfoque marca un paso firme hacia el futuro de la TC, alineado con la inteligencia artificial, la medicina de precisión y el análisis de imágenes de nueva generación. La reconstrucción avanzada con Deep Learning tiene como finalidad reducir drásticamente el ruido en las imágenes espectrales sin comprometer la resolución espacial, la textura natural ni la exactitud cuantitativa. Es entrenada utilizando imágenes de alta dosis reconstruidas con FBP (filtered back projection) que permite preservar una textura natural; La reconstrucción utiliza una red neuronal convolucional (CNN) para procesar sinogramas de GSI rápidamente, reduciendo el ruido en ambos componentes (agua/iodo). La integración de esta tecnología en entornos clínicos cotidianos promete optimizar la dosificación de radiación, mejorar la detección de patologías sutiles y apoyar futuros desarrollos en radiómica y medicina de precisión.</p>
--	------------------------------------	---

Nota. Descripción resumida de la literatura revisada sobre algoritmos de reconstrucción usados en imágenes de TC para eliminar artefactos.

Análisis de la Literatura Revisada: Artefactos en Imágenes de TC

Resultados

La revisión de literatura permitió identificar que los artefactos en estudios de tomografía computarizada (TC) constituyen un obstáculo persistente para la obtención de imágenes diagnósticas de calidad. De acuerdo con Sartori et al. (2015), estos se clasifican en cinco tipos: por movimiento, físicos, metálicos, técnicos y de reconstrucción, todos ellos capaces de generar distorsiones, duplicaciones y zonas de hiperdensidad que comprometen la interpretación clínica.

Cervantes Medina (2018) aporta una perspectiva comparativa entre sistemas digitales computarizados y sistemas directos, subrayando la influencia de variables como la configuración del equipo, el posicionamiento del paciente y la pericia del tecnólogo en la generación de artefactos. Esto refuerza la idea de que los errores no son únicamente atribuibles al equipo, sino al entorno operativo en su conjunto.

Asimismo, la literatura identifica estrategias comunes para mitigar los artefactos, entre ellas: protocolos de adquisición bien definidos, mantenimiento preventivo, calibración periódica del hardware y la capacitación continua del personal técnico. Sin embargo, también se evidencian vacíos relevantes, como la escasa existencia de estudios multicéntricos, la falta de métricas objetivas para la evaluación de artefactos y la limitada comparación entre algoritmos desarrollados por distintos fabricantes.

Tabla 6

Artefactos más comunes en tomografía computarizada y estrategias de mitigación.

Autor (año)	Tipo de artefacto	Causa principal	Efecto en la imagen	Estrategias de mitigación
Sartori et al. (2015)	Movimiento, físicos, metálicos, técnicos y de reconstrucción	Movimiento del paciente; propiedades físicas de los objetos; limitaciones del detector; algoritmos de reconstrucción	Distorsión, duplicación, zonas de hiper densidad que entorpecen la lectura	Capacitación continua del tecnólogo Mantenimiento preventivo del equipo Protocolos de adquisición estrictos (posicionamiento, técnica de barrido) Limpieza y calibración periódica del hardware
Cervantes Medina (2018)	Artefactos por sistemas digitales vs. Directos	Parámetros del equipo (kV, mA), posicionamiento y criterio del tecnólogo	Disminución de la calidad visual de la estructura anatómica	Estandarización de parámetros técnicos Formación en ajustes de protocolo Validación cualitativa tras cada adquisición Falta de estudios multicéntricos sobre artefactos mixtos Ausencia de métricas uniformes de cuantificación Escasa comparación directa entre fabricantes
Elementos sin resolver	—	—	—	

Nota. En la tabla, se observa que, aunque existen protocolos claros para mitigar los distintos tipos de artefactos.

Se evidencian que persisten vacíos en la estandarización de métricas y la comparación multicéntrica de resultados. Estas lagunas conforman el punto de partida para nuestro siguiente bloque de resultados.

Discusión

Los resultados evidencian que la presencia de artefactos en TC tiene una etiología multifactorial, abarcando tanto causas tecnológicas como humanas. Si bien los avances en reconstrucción de imagen, incluidos los algoritmos de inteligencia artificial, han demostrado capacidad para reducir ciertas distorsiones, su efectividad sigue dependiendo de variables

contextuales y operativas, como la adecuada configuración del equipo, la estandarización de protocolos y la experiencia del personal técnico.

La implementación de redes neuronales convolucionales (CNN), para la reducción de artefactos representa un avance significativo, pero su impacto clínico aún no está plenamente validado. La mayoría de los estudios disponibles son limitados en tamaño muestral, carecen de enfoques multicéntricos y no ofrecen comparaciones sistemáticas entre diferentes tecnologías. Esto limita su generalización y dificulta la toma de decisiones basada en evidencia robusta.

Además, persiste la necesidad de establecer métricas cuantitativas estandarizadas para evaluar la eficacia de los algoritmos en la reducción de artefactos, así como de diseñar indicadores que permitan monitorear su desempeño en condiciones clínicas reales. La ausencia de estos estándares dificulta la interoperabilidad entre sistemas y restringe el avance hacia una integración efectiva de la inteligencia artificial en la práctica radiológica.

Por tanto, es fundamental que la inteligencia artificial no se conciba como una solución aislada, sino como parte de un enfoque integral que contemple la formación continua del personal, el fortalecimiento de protocolos técnicos y la colaboración estrecha entre instituciones clínicas, académicas y fabricantes. Solo así será posible avanzar hacia una imagenología más precisa, segura y adaptada a las necesidades reales del entorno hospitalario.

Análisis de la Literatura Revisada: IA y Algoritmos de Reconstrucción en TC

Resultados

La comparación analítica de la literatura evidencia que la aplicación de IA, representa una alternativa innovadora frente a los métodos convencionales, particularmente redes neuronales convolucionales (CNN), como herramientas innovadoras para la reconstrucción de imágenes y la reducción de artefactos en tomografía computarizada (TC). A diferencia de los

métodos convencionales, permiten el aprendizaje automático a partir de grandes volúmenes de datos, identificando patrones normales y anómalos, incluso en presencia de distorsiones como el ruido o artefactos metálicos.

Zhang et al. (2017) proponen el modelo CNN-MAR, que combina imágenes originales con artefactos, imágenes corregidas por interpolación lineal (LI) y por compensación de endurecimiento del haz (BHC). Esta arquitectura multicanal permite que la red aprenda a distinguir estructuras anatómicas útiles de distorsiones, generando imágenes con una fidelidad anatómica superior. Sin embargo, este enfoque requiere una imagen "prior" bien definida, lo que introduce una limitación si las condiciones de adquisición inicial no son óptimas.

En contraste, algoritmos comerciales como AiCE (Canon Medical Systems) y TrueFidelity (GE Healthcare) operan directamente sobre sinogramas o datos de baja dosis sin necesidad de reconstrucciones previas. AiCE, basado en Deep Learning Reconstruction (DLR), mantiene la textura natural y reduce significativamente el ruido sin comprometer la resolución, incluso con dosis bajas. Por su parte, TrueFidelity utiliza datos espectrales multienergía para lograr imágenes de alta nitidez y mejorar la detectabilidad de lesiones pequeñas.

Tabla 7

Comparación de algoritmos de reconstrucción por inteligencia artificial en TC y sus principales resultados

Autor (año)	Algoritmo / Sistema	Datos de entrada	Medida de resultado	Principal hallazgo
Zhang et al. (2017)	CNN-MAR	Tres canales: imagen original con artefactos + LI + BHC	% reducción de artefactos metálicos	> 40 % de reducción de artefactos metálicos sin perder fidelidad anatómica; mejora de la calidad diagnóstica
Canon Medical Systems – AiCE DLR	AiCE	Proyecciones de baja dosis (22,6 mGy) del Aquilion Precision; objetos de 1,5 mm y Δ contraste 0,3 %	Detectabilidad de bajo contraste	Detecta objetos de 1,5 mm con 0,3 % de contraste manteniendo alta resolución y textura natural, reduciendo ruido sin aumentar dosis
GE Healthcare – TrueFidelity	TrueFidelity (DL-RSP)	Sinogramas espectrales (agua y yodo) en GSI; reconstrucción FBP vs CNN	Reducción de ruido (dB); mejora en resolución espacial; detectabilidad	Imágenes más nítidas y textura realista; permite dosis reducidas y mantiene consistencia multienergía; mejora la detectabilidad de lesiones pequeñas
Limitaciones y desafíos	—	—	—	Dependencia de datos representativos; costo computacional, validación regulatoria y formación del personal

Nota: Comparación de algoritmos de reconstrucción por inteligencia artificial en TC y sus principales resultados.

La Tabla 7 sintetiza estos hallazgos, permitiendo comparar los principales algoritmos, sus entradas, y los resultados clínicamente relevantes obtenidos. Todos los sistemas evaluados coinciden en su capacidad para disminuir artefactos y mejorar la calidad de imagen, especialmente en escenarios de baja dosis, lo cual tiene implicaciones directas para la seguridad del paciente.

Discusión

Los hallazgos revisados respaldan la hipótesis de que las redes neuronales convolucionales pueden desempeñar un papel fundamental en la mitigación de artefactos en TC. No obstante, una lectura crítica de los resultados sugiere que la efectividad de estos algoritmos está condicionada por múltiples factores operativos, técnicos y éticos.

En primer lugar, la comparación entre CNN-MAR y los algoritmos comerciales evidencia diferencias fundamentales en su aplicabilidad clínica. CNN-MAR depende de datos preprocesados y reconstrucciones limpias, lo que restringe su uso en entornos con limitaciones técnicas o alta variabilidad en la adquisición. En cambio, AiCE y TrueFidelity han demostrado mayor robustez al operar con datos clínicos reales, lo que favorece su integración en flujos de trabajo hospitalarios. Esto subraya la necesidad de evaluar cada algoritmo no solo por sus resultados en entornos controlados, sino por su adaptabilidad a contextos clínicos diversos.

Por otro lado, los beneficios técnicos observados, como la reducción de ruido, mejora en la resolución espacial y detectabilidad de lesiones, no deben ocultar los desafíos persistentes. Entre ellos se encuentran la dependencia de bases de datos extensas y representativas para el entrenamiento, la necesidad de infraestructura computacional avanzada, el alto costo de implementación y la escasa estandarización regulatoria para su validación clínica.

Además, existe un riesgo latente de ampliar la brecha tecnológica entre instituciones con recursos dispares, este se ha evidenciado en estudios recientes. Por ejemplo, en el Massachusetts General Hospital, la implementación de modelos basados en CNN logró una reducción del 40–50% en artefactos, mejorando la calidad diagnóstica y reduciendo repeticiones. Sin embargo, en instituciones de mediana complejidad, estas tecnologías son aún inaccesibles por la falta de hardware especializado y la limitada capacitación técnica, tal como lo señala Iglesias López

(2023), La adopción desigual de estos sistemas podría consolidar inequidades en el acceso a diagnósticos de alta calidad, por lo que su implementación debe ser acompañada de políticas que promuevan el acceso equitativo, la interoperabilidad tecnológica y la formación del talento humano.

Finalmente, es importante enfatizar que la inteligencia artificial no reemplaza el juicio clínico ni las competencias técnicas del profesional en radiología. La aparición de artefactos sigue estando vinculada en gran medida a errores humanos, como un posicionamiento incorrecto del paciente o la elección inadecuada de protocolos. Por tanto, la IA debe entenderse como un complemento que potencia la labor del tecnólogo, y no como una solución aislada. Su integración efectiva requiere un enfoque colaborativo, formación continua del personal y validación ética constante.

Conclusiones

Conclusiones Principales

La revisión documental permitió identificar una base creciente de evidencia científica que respalda la eficacia de las CNN en la detección y reducción de artefactos en imágenes por TC. Estas técnicas han demostrado que mejoran significativamente la calidad de las imágenes al reducir el ruido, preservar detalles anatómicos y superar las limitaciones de los métodos tradicionales. Sin embargo, también se evidenció que su adopción aún enfrenta desafíos técnicos y clínicos, como la necesidad de bases de datos extensas, la validación externa de los algoritmos y la compatibilidad con diversos sistemas de adquisición.

Implicaciones Clínicas

Minimizar estas distorsiones resulta esencial, para evitar errores interpretativos, disminuir repeticiones innecesarias y optimizar la exposición del paciente a la radiación. La mejora en la calidad de imagen repercute directamente en la confiabilidad diagnóstica, lo que fortalece la seguridad y eficiencia en los procesos asistenciales.

Limitaciones del Estudio

Una de las principales limitaciones encontradas en la literatura analizada fue la escasa comparación directa entre algoritmos de distintos fabricantes y la falta de protocolos estandarizados que permitan medir objetivamente el impacto de las CNN en distintos tipos de artefactos. Además, predominan los estudios in silico o descriptivos, con limitada validación clínica, lo cual restringe la generalización de los hallazgos.

Recomendaciones para Investigación Futura

Se recomienda impulsar estudios clínicos prospectivos, comparativos y multicéntricos que evalúen la eficacia de diferentes algoritmos de inteligencia artificial en situaciones reales.

Igualmente, es fundamental desarrollar métricas uniformes para cuantificar la mejora en la calidad de imagen y evaluar la integración de estos modelos en flujos de trabajo clínicos diversos. La colaboración entre desarrolladores tecnológicos, radiólogos y físicos médicos será clave para superar los desafíos actuales de implementación.

Referencias Bibliográficas

- Beauchamp, T. L., & Childress, J. F. (2019). *Principles of Biomedical Ethics* (8th ed.). New York: Oxford University Press.
- http://www.ucv.ve/fileadmin/user_upload/facultad_agronomia/Produccion_Animal/Produccion_Animal/Bioetica.pdf
- Camargo Gómez, DP, Benavides Beltrán, EA, García Contreras, NS, Rojas Rodríguez, SL, & Agudelo Saavedra, J. (2023). *Artefactos y artificios en tomografía computada*. Universidad Nacional Abierta ya Distancia - UNAD. Recuperado el 26 de febrero de 2025, de <https://repository.unad.edu.co/handle/10596/60195>
- Canon Medical Systems Europe. (2024, 7 junio). *Advanced Intelligent Clear-IQ Engine (AICE)* - Canon Medical Systems Spain. Canon Medical Systems Spain.
- <https://es.medical.canon/broadcasted-pages/products/computed-tomography/advanced-intelligent-clear-iq-engine-aice/>
- Cervantes Medina, RV (2018). *Evaluación de artefactos en imágenes radiográficas digitales procedentes de equipo radiológico computarizado vs equipo digital directo*. Universidad Nacional Federico Villareal. Recuperado el 26 de febrero de 2025, de https://repositorio.unfv.edu.pe/bitstream/handle/20.500.13084/2125/UNFV_Cervantes_Medina_Rosa_Victoria_Maestria_2018.pdf?sequence=1
- Chen, J; Liu, D; Zhao, W. (2023). *Multi-stage deep learning artifact reduction for computed tomography*. arXiv. <https://arxiv.org/abs/2309.00494>
- Chen, G. H., et al. (2024). *Deep learning-based algorithms for low-dose CT imaging: A review*. *European Journal of Radiology*. 167. 110000. <https://doi.org/10.1016/j.ejrad.2024.111355>

- Chen, Z; et al. (2024). Portable head CT motion artifact correction via diffusion-based model. *Computerized Medical Imaging and Graphics*, 105, 102260.
<https://doi.org/10.1016/j.compmedimag.2024.102478>
- Costa, J; Soria, J. (2015). Tomografía computarizada dirigida a Técnicos Superiores en Imagen para el diagnóstico. Booksmedicos.org.
https://drive.google.com/file/d/1SvvZKcKtepPHrvGjP1_01FCbuJErcKt1/view?usp=sharing
- Cozzi, A., Cè, M., De Padova, G., Libri, D., Caldarelli, N., Zucconi, F., . . . Cellina, M. (2023). 48 Deep Learning-Based Versus Iterative Image Reconstruction for Unenhanced Brain CT: A Quantitative Comparison of Image Quality. *Tomography*, 9(5), 1629–1637.
<https://doi.org/10.3390/tomography9050130>
- De Barcelona, T. de F. de G. R. en la E. T. D. de T. (s/f). Estudio y aplicación de las redes neuronales convolucionales 3D. Upc.edu. Recuperado el 26 de marzo de 2025, de <https://upcommons.upc.edu/bitstream/handle/2117/124877/Estudio+y+aplicaci%C3%B3n+de+las+redes+neuronales+convolucionales+3D.pdf?sequence=1>
- Gjesteby, L; Yang, Q; Xi, Y; Claus, B; Jin, Y; De Man, B; Wang, G; & Shan, H. (2017). Deep learning methods for CT image-domain metal artifact reduction. *Métodos de Aprendizaje Profundo Para la Reducción de Artefactos Metálicos En el Dominio de la Imagen de TC*, 31. <https://doi.org/10.1117/12.2274427>
- Hsieh, J., et al. (2019). A new era of image reconstruction: TrueFidelity Technical White Paper on Deep Learning Image Reconstruction. GE Healthcare. Recuperado de <https://www.gehealthcare.com/-/jssmedia/files/truefidelity/truefidelity-white-paper-jb68676xx-doc2287426.pdf?rev=-1>

- Iglesias López, Dannier. (2023). Impacto de la Inteligencia Artificial en la Radiología. Revista Cubana de Informática Médica, 15(1), . Epub 01 de junio de 2023. Recuperado en 04 de marzo de 2025, de http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S1684-18592023000100013&lng=es&tlng=es.
- Jia H, Zhang J, Ma K, Qiao X, Ren L, Shi X. Application of convolutional neural networks in medical images: a bibliometric analysis. Quant Imaging Med Surg. 2024 May 1;14(5):3501-3518. doi: 10.21037/qims-23-1600
- Ley 23 “Sobre derechos de autor” (1983).
<http://derechodeautor.gov.co:8080/documents/10181/182597/23.pdf/a97b8750-8451-4529-ab>
- Lin, Y., Yu, H., & Wang, G. (2019). DuDoNet: Dual Domain Network for CT Metal Artifact Reduction. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 10512–10521. <https://doi.org/10.1109/CVPR.2019.01076>
- 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>
- Park, S., Kim, H., & Lee, J. (2024). Capability enhancement of the X-ray micro-tomography system via ML-assisted approaches. arXiv. <https://arxiv.org/abs/2402.05983>
- Philips - Reconstrucción iterativa de modelo (IMR) Tecnología de reconstrucción. (s. f.). Philips.
<https://www.philips.es/healthcare/product/HCNCTD449/reconstruccin-iterativa-de-modelo-imr-tecnologa-de-reconstruccin>

- Rodríguez, L., & Gómez, A. (2022). Aplicación para la reducción de artefactos metálicos en imágenes de Tomografía Computarizada (TC). Dialnet.
<https://dialnet.unirioja.es/descarga/articulo/8590216.pdf>
- Sabottke, C. F., & Spieler, B. M. (2020). The effect of image resolution on deep learning in radiography. *Radiology. Artificial Intelligence*, 2(1), e190015.
<https://doi.org/10.1148/ryai.2019190015>
- 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>
- Serrano, R. (2023). Optimización basada en algoritmos de IA para la mejora de la calidad de imagen en tomografía computarizada. Universidad Nacional Abierta y a Distancia.
<https://repository.unad.edu.co/bitstream/handle/10596/65625/rserranose.pdf>
- Singh, R., Digumarthy, S. R., Muse, V. V., Kambadakone, A. R., Blake, M. A., Tabari, A., Hoi, Y., Akino, N., Angel, E., Madan, R., & Kalra, M. K. (2020). Image Quality and Lesion Detection on Deep Learning Reconstruction and Iterative Reconstruction of Submillisievert Chest and Abdominal CT. *American Journal Of Roentgenology*, 214(3), 566-573. <https://doi.org/10.2214/ajr.19.21809>
- Systems, C. M. (s. f.). AiCE Deep Learning Reconstruction | Bringing the power of Ultra-High Resolution CT to routine imaging | Canon Medical Systems.
https://eu.medical.canon/publication/ct/2019WP_AiCE_Deep_Learning
- TrueFidelity CT. (s. f.). GE HealthCare (Australia & New Zealand).
<https://www.gehealthcare.com.au/products/computed-tomography/truefidelity>

- 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>
- Vega Jaramillo, A. (2010). Manual de derecho de autor. <https://www.derechodeautor.gov.co/sites/default/files/2024-08/10.%20Manual%20de%20derecho%20de%20autor%20escrito%20por%20Alfredo%20Vega.pdf>
- Zhang, H., Wang, Y., & Li, X. (2023). Improving automated hemorrhage detection in sparse-view computed tomography via deep convolutional neural network-based artifact reduction. arXiv. <https://arxiv.org/abs/2303.09340>
- Zhang, Y., Chu, Y., y Yu, H. (2017). Reducción de artefactos metálicos en imágenes de tomografía computarizada de rayos X mediante una red neuronal convolucional. Actas de SPIE , 12(2275592). <http://dx.doi.org/10.1117/12.2275592>
- Zhang, C., Xu, Y., Zhang, Y., & Zhang, Y. (2018). CT artifact reduction via U-net CNN. Proceedings of SPIE - Medical Imaging, 10574, 105742C. <https://doi.org/10.1117/12.2293903>