

**Artefactos de tomografía computarizada como limitante diagnóstica y evaluación de uso
de redes neuronales para su detección**

Adriana Danitza Hidalgo Hidalgo

María Fernanda Castelblanco Hernández

María Paula Bohórquez Arrieta

Sharik Camila Guevara Pérez

Yuli Tatiana Echeverri Jara

Asesor

Edna Rocío Jamaica Guio

Universidad Nacional Abierta y a Distancia - UNAD

Escuela de ciencias de la salud - ECISA

Tecnología en Radiología e imágenes diagnósticas

2025

Agradecimientos

Culminar este trabajo de grado ha representado un proceso pleno de aprendizajes, desafíos y crecimiento constante, el cual no habría sido posible sin el apoyo y acompañamiento de quienes hicieron parte de este recorrido académico.

Agradecemos a la Universidad Nacional Abierta y a Distancia (UNAD) por brindarnos un espacio de formación integral, así como los recursos y el acompañamiento académico necesarios para nuestro desarrollo profesional y para la culminación exitosa de este proyecto.

Expresamos nuestro más sincero reconocimiento a los tutores Edna Rocío Jamaica y Alberto Guzmán Avilés, por su compromiso, dedicación, orientación y valiosa guía, elementos fundamentales en cada etapa del proyecto y determinantes para alcanzar los objetivos propuestos.

Finalmente, extendemos un agradecimiento especial a todas las personas que, con sus conocimientos, tiempo y disposición, contribuyeron al desarrollo y fortalecimiento de este trabajo de grado. Su apoyo ha sido significativo para la realización de este logro académico.

Dedicatoria

Dedicamos este trabajo, ante todo, a Dios, por ser nuestra luz en los momentos de incertidumbre, nuestra fortaleza en los desafíos y la fuente de sabiduría que nos permitió avanzar con determinación. Sin Su guía, este camino no habría sido posible.

A nuestros padres, abuelos y hermanos quienes, con su amor infinito, sus palabras de aliento y su confianza inquebrantable nos sostuvieron incluso en los días más difíciles. Cada logro alcanzado es también fruto de su esfuerzo, su ejemplo y sus sacrificios silenciosos. Gracias por enseñarnos a perseverar y por creer en nosotros aun cuando dudábamos.

A la Universidad Nacional Abierta y a Distancia (UNAD), institución que nos brindó un espacio de crecimiento académico y personal, y que acompañó cada etapa de esta formación con compromiso y dedicación.

Y a nuestros compañeros de curso, con quienes compartimos dudas, aprendizajes, risas, retos y metas comunes. Gracias por el apoyo mutuo, la solidaridad y el espíritu de equipo que hicieron de este proceso una experiencia más llevadera y profundamente significativa.

Resumen

La presente investigación surge a partir de un problema clínico identificado en la práctica radiológica: la presencia de artefactos en imágenes de Tomografía Computarizada (TC), que comprometen la calidad diagnóstica. Estos artefactos, generados principalmente por movimientos involuntarios del paciente durante la adquisición o por limitaciones del software del equipo, actúan como ruido visual que puede ocultar lesiones o simular patologías inexistentes, incidiendo negativamente en la precisión del diagnóstico médico. El estudio se enfoca en evaluar el potencial de las redes neuronales, una rama avanzada de la inteligencia artificial, para la detección automática de estos artefactos. Se plantea que dichas redes pueden ser entrenadas para reconocer patrones asociados a imperfecciones en las imágenes, siendo una herramienta complementaria para los radiólogos.

Palabras clave: Tomografía computarizada, inteligencia artificial, redes neuronales, artefactos, diagnostico.

Abstract

This research arises from a clinical problem identified in radiological practice: the presence of artifacts in Computed Tomography (CT) images, which compromise diagnostic quality. These artifacts, mainly caused by involuntary patient movements during image acquisition or by software limitations of the equipment, act as visual noise that can obscure lesions or simulate nonexistent pathologies, negatively affecting the accuracy of medical diagnosis. The study focuses on evaluating the potential of neural networks, an advanced branch of artificial intelligence, for the automatic detection of these artifacts. It is proposed that such networks can be trained to recognize patterns associated with image imperfections, serving as a complementary tool for radiologists.

Keywords: Computed tomography, artificial intelligence, neural networks, artifacts, diagnosis.

Tabla de contenido

Introducción	9
Planteamiento del problema.....	11
Objetivos.....	15
Objetivo general.....	15
Objetivos específicos	15
Marco teórico.....	16
Generalidades de la tomografía.....	16
Definición y Función	16
Principios Físicos de Funcionamiento.....	16
Proceso de Adquisición y Reconstrucción de la Imagen	16
Artefactos en tomografía computarizada.....	17
Definición de artefacto.....	17
Artefactos por movimiento	17
Artefactos por software/Reconstrucción	17
Capas convolucionales.....	18
detección vs. corrección.....	19
Sensibilidad y Especificidad	19
Generalización del Modelo	19
Interpretabilidad (Caja Negra)	19
Marco metodológico	20

	7
Enfoque de la investigación	20
Diseño de la investigación	20
Fases propuestas para nuestro marco metodológico	21
Análisis de datos	22
Arquitectura de la IA y sus aplicaciones específicas	22
Arquitecturas U-Net para segmentación y corrección	23
Redes generativas adversas (GAN) para reconstrucción avanzada.....	23
Frecuencia de Estudio por Tipo de Artefacto y Vacíos Identificados.....	25
Artefactos Relacionados con Software o Metal.....	25
Principales vacíos de la investigación identificados	25
Síntesis y contrapuntos.....	26
Resultados	27
Conclusiones	29
Bibliografía.....	31

Índice de Tablas

Tabla 1 <i>Resumen de Hallazgos: Rendimiento y Eficiencia de Modelos de IA en Tomografía Computarizada</i>	23
---	----

Introducción

La tomografía computarizada (TC) se ha consolidado como una herramienta esencial en el diagnóstico médico moderno, gracias a la capacidad para generar imágenes abarca desde la evaluación de traumatismos craneoencefálicos hasta el diagnóstico de patologías cardiovasculares, oncológicas y neurológicas, convirtiéndola en un pilar de medicina contemporánea. Sin embargo, la calidad diagnóstica de las imágenes obtenidas mediante TC puede verse comprometida con la presencia de artefactos, los cuales distorsionan la representación real de los tejidos y órganos, afectando directamente la precisión clínica.

Entre los artefactos más frecuentes y problemáticos se encuentran aquellos generados por el movimiento del paciente ya sea voluntario o involuntario y los derivados del proceso digital de la imagen, como el endurecimiento del haz o el volumen parcial. Estas alteraciones no solo dificultan la interpretación visual, sino que puede ocultar lesiones críticas, simular enfermedades inexistentes o alterar parámetros clínicos relevantes, generando falsos diagnósticos y decisiones terapéuticas erróneas. Aunque existen métodos convencionales para mitigar estos efectos, su eficacia es limitada. Ante el desafío de la inteligencia artificial (IA) y en particular las redes neuronales convulsiones (CNN) se representa como una alternativa innovadora y prometedora, estas arquitecturas han demostrado una notable capacidad para aprender patrones complejos en imágenes médicas, permitiendo la detección y corrección automática de artefactos con un alto grado de precisión. La implantación no solo mejora la calidad de las imágenes, sino que optimiza el tiempo de análisis, reduce la variabilidad diagnóstica y fortalece la seguridad del paciente.

Este trabajo propone analizar el impacto de los artefactos en la TC como una barrera crítica para la precisión diagnóstica, y explorar el potencial de las CNN como solución tecnológica para su detección y mitigación; a través de un enfoque clínico, técnico, ético, se busca contribuir al desarrollo de sistemas automatizados que eleven la confiabilidad del diagnóstico por imagen, en el marco de una medicina digital más segura, eficiente y humanizado.

Planteamiento del problema

La Tomografía Computarizada (TC) es una modalidad de imagen médica fundamental para el diagnóstico rápido y preciso de una amplia gama de patologías, desde traumatismos craneoencefálicos hasta enfermedades vasculares. Sin embargo, la calidad diagnóstica de las imágenes de TC se ve frecuentemente comprometida por la aparición de artefactos, siendo los relacionados con el movimiento del paciente (voluntario o involuntario) y los inherentes al procesamiento software de la imagen (como los artefactos de endurecimiento del haz o de volumen parcial) los más prevalentes y desafiantes.

Estos artefactos no son solo imperfecciones estéticas, sino que representan un problema clínico muy importante. Pueden ocultar patologías críticas (como una pequeña hemorragia subdural), simular la presencia de enfermedades inexistentes o cuantificar erróneamente parámetros vitales, conduciendo directamente a diagnósticos erróneos, falsos negativos, falsos positivos y, en última instancia, a un manejo clínico inapropiado del paciente. Si bien existen técnicas convencionales de corrección y los radiólogos experimentados los reconocen, estos métodos son insuficientes: las técnicas de software tradicionales no siempre son efectivas para artefactos complejos, y la evaluación humana está sujeta a la subjetividad, la fatiga y la alta carga laboral, lo que introduce una variabilidad inaceptable en procesos diagnósticos que requieren la máxima precisión.

Ante esta limitación significativa, surge la necesidad de explorar soluciones innovadoras, automatizadas y confiables. Las redes neuronales convolucionales (CNN), han demostrado un rendimiento excepcional en tareas de visión por computadora, incluyendo la clasificación, detección y segmentación de imágenes médicas. Su capacidad para aprender patrones complejos directamente desde los datos las convierte en una opción ideal para

aprender a identificar y corregir los sutiles patrones que caracterizan a los artefactos en las imágenes de TC.

Por lo tanto, el problema central de investigación se formula a través de las siguientes preguntas: ¿De qué manera los artefactos por software y movimiento en TC constituyen una barrera crítica para la precisión diagnóstica? Y, en consecuencia, ¿cómo pueden las redes neuronales convolucionales ser diseñadas, entrenadas e implementadas para detectar y mitigar automáticamente estos artefactos, superando las limitaciones de los métodos actuales y elevando así la confiabilidad del diagnóstico por imagen.

Justificación

La precisión diagnóstica en la interpretación de imágenes médicas constituye un pilar fundamental en la práctica clínica, dado que de ella dependen decisiones terapéuticas que inciden directamente en el estado de salud y el pronóstico de los pacientes. En este sentido, la presencia de artefactos en las imágenes representa una limitación significativa, pues puede comprometer la calidad visual, inducir errores en la interpretación y, en consecuencia, conducir a diagnósticos incorrectos. Este riesgo es clínicamente relevante, ya que los artefactos pueden enmascarar u ocultar patologías reales o, por el contrario, simular hallazgos inexistentes. Un diagnóstico errado puede desencadenar intervenciones médicas innecesarias, retrasadas o incluso omisiones en el tratamiento oportuno.

La presente investigación propone abordar esta problemática desde una perspectiva clínica, social y tecnológica, con el propósito de fortalecer la capacidad diagnóstica del personal especializado. Para ello, se plantea la incorporación de redes neuronales convolucionales (CNN), basadas en inteligencia artificial (IA), como herramienta para la detección y mitigación automática de artefactos en imágenes médicas. La implementación de esta tecnología no solo optimiza el proceso de interpretación, sino que también reduce significativamente la tasa de errores diagnósticos, minimiza la necesidad de reprocesos o repetición de estudios y garantiza mayor seguridad y confiabilidad en los resultados entregados al paciente.

Por lo anterior, la propuesta se justifica en la necesidad de acompañar el avance de la práctica médica con el desarrollo tecnológico emergente. La integración de sistemas basados en IA, como las CNN, se posiciona como una solución moderna y eficiente que mejora la calidad de las imágenes diagnósticas, optimiza el tiempo de análisis y contribuye

a ofrecer diagnósticos más precisos y confiables, favoreciendo así tanto al personal sanitario como a la población usuaria de los servicios de salud.

Objetivos

Objetivo General

Analizar el potencial y las limitaciones de las redes neuronales convolucionales en la detección y corrección de artefactos por movimiento y software en imágenes de TC, mediante una revisión sistemática de la literatura científica reciente.

Objetivos Específicos

Categorizar las arquitecturas de CNN predominantes en la literatura actual, identificando aquellas con mayor eficacia en el procesamiento de imágenes de TC.

Sintetizar los indicadores de rendimiento reportados en los estudios, para evaluación de la fiabilidad de la detección automática.

Identificar los desafíos metodológicos y técnicos que dificultan la transición de estos modelos de IA desde la investigación hacia la práctica clínica real.

Valorar el impacto de la reducción automática de artefactos en la calidad del diagnóstico médico y la eficiencia del flujo de trabajo radiológico frente a métodos convencionales.

Marco Teórico

Generalidades de la Tomografía

La Tomografía Computarizada (TC) se ha consolidado como un pilar fundamental en el diagnóstico médico no invasivo. Desde su introducción clínica, ha evolucionado para ofrecer representaciones volumétricas de alta fidelidad que permiten la detección temprana de patologías críticas con una resolución espacial sin precedentes (Kalender, 2021).

Definición y Función

La TC es un método de diagnóstico por imagen que emplea radiación ionizante (rayos X) para generar cortes transversales del organismo. Su función principal es la reconstrucción de estructuras anatómicas en planos axiales, coronales y sagitales, superando la limitación de la radiografía convencional al eliminar la superposición de tejidos y permitir una evaluación densitométrica precisa (Franco López & Fernández Pérez, 2018).

Principios Físicos de Funcionamiento. El funcionamiento de la TC se rige por la atenuación de los fotones de rayos X al interactuar con la materia. El grado de absorción depende de la densidad del tejido y el número atómico efectivo de los componentes orgánicos, valores que se cuantifican mediante coeficientes de atenuación lineal y se expresan en la escala de Unidades Hounsfield (HU) (Bushberg et al., 2011).

Proceso de Adquisición y Reconstrucción de la Imagen. La adquisición produce datos proyectivos o sinogramas. El proceso de reconstrucción consiste en transformar estos datos crudos en una matriz de píxeles inteligible. Tradicionalmente se ha utilizado la Retroproyección Filtrada (FBP); sin embargo, los sistemas modernos emplean Reconstrucción Iterativa, la cual utiliza bucles de retroalimentación matemática para

reducir el ruido y mejorar la calidad de imagen con dosis menores de radiación (Galeano-Galeano et al., 2021).

Artefactos en Tomografía Computarizada

En el entorno radiológico, un artefacto se define como cualquier discrepancia sistemática entre los coeficientes de atenuación representados en la imagen reconstruida y los valores reales del objeto escaneado (Barrett & Keat, 2004).

Definición de Artefacto

Se refiere a cualquier característica en la imagen que no está presente en el objeto original. Estos elementos degradan la calidad diagnóstica y pueden conducir a errores de interpretación clínica al simular o enmascarar patologías.

Artefactos por Movimiento

Representan el desafío técnico más frecuente y se originan por desplazamientos voluntarios o involuntarios del paciente (respiración, latidos cardíacos). Físicamente, el movimiento genera una inconsistencia en la recolección de datos espaciales durante el barrido, lo que se traduce en borrosidad, imágenes "fantasma" (*ghosting*) y bandas de sombra que invalidan la nitidez de los bordes anatómicos (Sartori et al., 2015).

Artefactos por Software/Reconstrucción

Estos errores derivan de las limitaciones de los algoritmos de procesamiento digital. El aliasing ocurre por un muestreo insuficiente de los datos, mientras que el endurecimiento del haz crea franjas oscuras entre estructuras densas debido a la absorción selectiva de fotones de baja energía. Estos artefactos dificultan la cuantificación precisa de tejidos en áreas críticas como la base del cráneo (Martín Cuartero et al., 2018).

Inteligencia Artificial y Salud

La Inteligencia Artificial (IA) ha permitido una transición hacia la medicina de precisión, optimizando la interpretación y el flujo de trabajo clínico mediante el aprendizaje automatizado de patrones (Litjens et al., 2017).

Arquitecturas de Redes Neuronales Convolucionales (CNN)

Las CNN son modelos de aprendizaje profundo diseñados para procesar datos con topología de rejilla. Sus capas fundamentales incluyen:

Capas Convolucionales. Emplean filtros para la extracción automática de características espaciales.

Capas de Pooling Reducen la dimensionalidad para mejorar la eficiencia computacional, Activación (ReLU) introduce no-linealidad para permitir el aprendizaje de patrones complejos (Krizhevsky et al., 2012).

Variantes Comunes

U-Net. Caracterizada por una estructura simétrica, es el estándar para segmentación y limpieza de imágenes médicas, preservando la localización espacial de los tejidos (Ronneberger et al., 2015).

ResNet. Utiliza conexiones de salto que permiten entrenar redes de gran profundidad evitando la degradación de la precisión (He et al., 2016).

GANs (Redes Generativas Antagónicas). Compuestas por un generador y un discriminador que compiten para crear imágenes corregidas con un realismo superior (Goodfellow et al., 2014).

Procesamiento de Imágenes Médicas mediante CNN

Pre-procesamiento y Aumento de Datos. Incluye la normalización de intensidades y el Data Augmentation. Esta técnica expande artificialmente el conjunto de datos mediante

rotaciones y variaciones de contraste, permitiendo que el modelo aprenda a identificar artefactos bajo diversas condiciones clínicas (Talamantes Román, 2024).

Detección vs. Corrección. La detección se limita a la identificación de la anomalía técnica que invalida el estudio. La corrección emplea algoritmos para reconstruir la información perdida por el artefacto, garantizando que el post-procesamiento no elimine información anatómica real (Zhou et al., 2020).

Métricas de Evaluación

La fiabilidad se mide mediante:

Sensibilidad y Especificidad. Certeza en la detección de fallos.

Métricas de Calidad: El PSNR (relación pico señal-ruido) y el SSIM (índice de similitud estructural) aseguran que la imagen corregida sea fiel a la anatomía original (Flores Maza & González Martínez, 2025).

Desafíos en el Entorno Clínico

Generalización del Modelo. Un desafío crítico es la variabilidad técnica entre fabricantes de escáneres (ej. Siemens vs. GE), lo que puede causar que una IA entrenada en un hospital falle en otro debido a diferencias en los protocolos de adquisición (Zhou et al., 2020).

Interpretabilidad (Caja Negra). La falta de transparencia sobre cómo la IA toma decisiones genera desconfianza. Es imperativo que el radiólogo comprenda el proceso de "limpieza" de la imagen para garantizar que no se hayan borrado hallazgos patológicos reales bajo la apariencia de un artefacto (Litjens et al., 2017).

Marco metodológico

La presente investigación se define como un estudio de carácter descriptivo y exploratorio (Arias, 2012). Es de naturaleza exploratoria debido a que aborda un campo de vanguardia en la radiología digital: la implementación específica de redes neuronales para la mitigación de artefactos de movimiento y software en tomografía computarizada (TC). Este enfoque permite familiarizarse con una tecnología cuya aplicación clínica aún se encuentra en fases de validación y desarrollo.

Asimismo, posee un nivel descriptivo, ya que se orienta a detallar las propiedades y características técnicas de las arquitecturas de aprendizaje profundo identificadas en la literatura. El estudio permite caracterizar el desempeño de las Redes Neuronales Convolucionales (CNN) y documentar los desafíos metodológicos persistentes señalados por la comunidad científica.

Enfoque de la Investigación

El estudio se desarrolla bajo un enfoque cualitativo, fundamentado en la interpretación de contenidos y la síntesis de evidencia teórica. A diferencia de los estudios cuantitativos tradicionales, este análisis no se centra en el procesamiento estadístico de datos primarios, sino en una revisión crítica y detallada de la literatura científica existente, que incluye artículos de investigación original, revisiones sistemáticas y estudios de caso. Este enfoque permite comprender las tendencias emergentes, la evolución de los métodos de IA y las implicaciones éticas y clínicas de su uso en el entorno radiológico.

Diseño de la Investigación

El diseño adoptado es la Revisión Sistemática de la Literatura. Este diseño metodológico permite mapear el conocimiento existente de manera rigurosa, objetiva y

replicable. Siguiendo protocolos estructurados para la búsqueda, selección, evaluación y síntesis de la evidencia, se garantiza que la investigación proporcione una visión integral sobre el estado actual de las redes neuronales aplicadas a la corrección de imágenes por TC, minimizando el sesgo de selección.

Fases propuestas para nuestro marco metodológico

Fase 1 Búsqueda Sistemática

Definiremos palabras clave en español e inglés (ej: "artefactos de movimiento TC", "deep learning CT artifacts", "convolutional neural networks motion correction") y las aplicaremos en bases de datos científicas como PubMed, Google Académico y IEEE Xplore.

Fase 2 Selección y Cribado

Se establecen criterios de inclusión y exclusión. Por ejemplo, se incluirán artículos de los últimos 5 años que aborden específicamente la detección o corrección de artefactos con IA, y excluirémos los que se centren solo en otros tipos de artefactos o en otras modalidades de imagen.

Fase 3 Análisis y Síntesis.

Se extraerá la información clave de los artículos seleccionados tipo de red neuronal usada, base de datos de imágenes empleada, resultados de precisión, limitaciones reportadas y la organizaremos en tablas o matrices para identificar patrones y tendencias.

Fase 4 Conclusiones

Finalmente, se integrará toda la información para responder a los objetivos y proponiendo direcciones futuras para la investigación.

Análisis de Datos

La revisión sistemática de la literatura permitió realizar un análisis estructurado y comparativo sobre la aplicación de redes neuronales para manejar artefactos en TC. Los resultados se organizan en tres áreas críticas: las arquitecturas de IA utilizadas para propósitos específicos, su desempeño métrico cuantificable y los tipos de artefactos predominantes en la investigación.

Arquitecturas de IA y sus Aplicaciones Específicas

El análisis evidencia que la elección del modelo de IA está intrínsecamente ligada al objetivo clínico, siendo cada arquitectura superior para una tarea concreta.

Redes Neuronales Convolucionales (CNN) para Clasificación: Se emplean como la primera línea de control de calidad automatizado. Su función principal es detectar y clasificar si una imagen contiene artefactos graves que la hacen no diagnóstica. Por ejemplo, Dasegowda et al. (2023) desarrollaron un algoritmo de este tipo para revisar automáticamente angiografías pulmonares por TC, logrando una sensibilidad del 94% para identificar estudios con artefactos de movimiento, demostrando su eficacia como filtro inicial.

Arquitectura U-Net para Segmentación y Corrección

Es el modelo de referencia para tareas que requieren precisión a nivel de píxel, como la corrección de artefactos. Su diseño en "U" con conexiones residuales permite conservar los detalles anatómicos finos mientras elimina el ruido o las distorsiones. Kumschier et al. (2024) utilizaron una variante de U-Net para eliminar artefactos en forma de estrías en TC de campo oscuro, logrando una mejora del 35% en el índice SSIM, lo que confirma su capacidad para restaurar la estructura anatómica sin degradarla.

Redes Generativas Adversarias (GAN) para Reconstrucción Avanzada

Estas redes son las más potentes para escenarios complejos donde se ha perdido información anatómica. Aprenden a rellenar o reconstruir las regiones ocultas por artefactos graves (como los metálicos) generando contenido visual realista. Fernández (2025) destaca que los métodos basados en GAN superan significativamente a las técnicas clásicas de reducción de artefactos metálicos, ya que no solo suavizan la imagen, sino que sintetizan información anatómica plausible.

Desempeño Métrico Comparativo

La siguiente tabla sintetiza el rendimiento reportado por los estudios revisados, clave para evaluar la viabilidad clínica de esta herramienta.

Tabla 1

Resumen de Hallazgos: Rendimiento y Eficiencia de Modelos de IA en Tomografía Computarizada

Estudio (Autor, Año)	Arquitectura principal	Tarea Principal	Métrica Clave (Rendimiento)	Tiempo de Procesamiento (vs. Método Tradicional)
Dasegowda et al. (2023)	CNN de Clasificación	Detección de artefactos por movimiento en angio-TC	Sensibilidad:94%	Procesamiento en segundos vs. revisión manual, que puede tomar minutos por estudio.

Kumschier et al. (2024)	U-Net (variante)	Corrección de artefactos en TC de campo oscuro	SSIM: Mejora del 35%	No especificado, pero las CNN de inferencia suelen ser más rápidas que los métodos iterativos clásicos.
Carrizales et al. (2024)	Modelo de Aprendizaje Profundo	Detección de artefactos en 4DCT	Precisión: >90%	El análisis automatizado permite evaluar volúmenes 4D completos de manera eficiente.
J. et al. (2021)	Modelo de Aprendizaje Profundo	Eliminación de artefactos por movimiento de cabeza	PSNR/SSIM: Mejora significativa	Destacan la eficiencia computacional del modelo propuesto.

Nota. Autoría propia.

Interpretación de Métricas

La alta sensibilidad (94%) reportada por Dasegowda et al. es crucial para un sistema de filtrado, ya que garantiza que pocos estudios defectuosos pasen desapercibidos. Por otro lado, la mejora en SSIM reportada por Kumschier et al. valida que la corrección no solo mejora el aspecto visual, sino que preserva fielmente la estructura anatómica, un requisito indispensable para el diagnóstico.

Frecuencia de Estudio por Tipo de Artefacto y Vacíos Identificados

El análisis de frecuencia revela una distribución desigual en el esfuerzo investigador:

Artefactos por Movimiento

Son los más estudiados, con múltiples investigaciones enfocadas en movimiento voluntario (cabeza), respiratorio y cardíaco (4DCT). Esto refleja su alta incidencia en la práctica clínica diaria y su impacto directo en diagnósticos urgentes, como en el trauma o la embolia pulmonar.

Artefactos Relacionados con Software o Metal. Aunque son muy disruptivos, la literatura es algo menor, pero de avance rápido, con soluciones que han evolucionado de métodos clásicos a enfoques con GAN.

Principales Vacíos de Investigación Identificados

Falta de Generalización y Validación Clínica Rigurosa

Como señalan Hernández y Suárez (2023), un vacío crítico es la escasa validación de estos modelos en entornos clínicos reales y heterogéneos (diferentes marcas de escáneres, protocolos, poblaciones pacientes). La mayoría se prueba en conjuntos de datos controlados, lo que limita la confianza en su aplicabilidad universal.

Ausencia de Bases de Datos Estandarizadas. Se identificó consistentemente la carencia de repositorios públicos grandes, diversos y anotados específicamente para artefactos en TC. Esta limitante frena el desarrollo, la comparación justa de algoritmos y la reproducibilidad de la investigación, tal como lo sugiere la iniciativa de la AAPM (2022) para crear un desafío sobre el tema.

Optimización del Flujo de Trabajo Clínico. Existe poca investigación sobre cómo integrar de manera efectiva estas herramientas en los sistemas de información radiológica (PACS) y en el flujo de trabajo del radiólogo. Estudios sobre la interfaz usuario-IA y el impacto real en la eficiencia del diagnóstico son áreas necesarias para la adopción masiva.

Síntesis y Contrapuntos

En conjunto, los autores concuerdan en que las CNN, y en particular arquitecturas como U-Net y GAN, son estrategias muy superiores a los métodos tradicionales para detectar y corregir artefactos, alcanzando precisiones superiores al 90% y mejorando métricas de calidad de imagen.

Sin embargo, se identifica un contrapunto clave: mientras que los resultados técnicos (PSNR, SSIM, sensibilidad) son positivos en entornos controlados, existe un escepticismo compartido sobre la preparación para la implementación clínica a gran escala. La principal contradicción no está en la efectividad del algoritmo, sino entre el éxito en el laboratorio y los obstáculos para su traslación a la rutina hospitalaria, dominada por la heterogeneidad de datos y la necesidad de integración operativa.

Resultados

La revisión sistemática de la literatura científica evidencia el destacado potencial de las redes neuronales convolucionales (CNN) para abordar el problema de los artefactos en imágenes de tomografía computarizada (TC), con hallazgos específicos:

Detección de Artefactos de Movimiento

Carrizales et al. (2024) demostraron que las CNN pueden alcanzar una precisión superior al 90% en la detección automática de artefactos en estudios de tomografía computarizada 4D (4DCT), lo que representa un avance importante para la mejora de la calidad de imagen y la confiabilidad diagnóstica. De manera complementaria, Quan y Li (2021) desarrollaron un método de aprendizaje profundo que elimina eficazmente artefactos de movimiento de cabeza, lo que contribuye a mejoras sustanciales en la interpretación clínica.

Supresión de Artefactos Metálicos

En el ámbito de los artefactos causados por la presencia de metales, Kumschier et al. (2024) evidenciaron que las CNN son capaces de suprimir de forma eficiente los artefactos de tipo estrías generados por implantes metálicos en las imágenes. Además, Fernández (2025) concluye que los métodos basados en inteligencia artificial superan a las técnicas clásicas en la reducción y corrección de artefactos metálicos, optimizando la calidad visual de las imágenes.

Avances en la Reconstrucción de Imagen

Wang et al. (2020) destacan que el aprendizaje automático ha revolucionado el proceso de reconstrucción de imágenes TC, abriendo nuevas fronteras para la corrección automática de artefactos, lo que puede potenciar la precisión diagnóstica y la reducción de errores asociados a defectos en la imagen.

Desafíos en la Generalización de Modelos

Finalmente, Hernández y Suárez (2023) señalan que, pese a los avances identificados, existen dificultades importantes para generalizar los modelos de CNN entrenados en bases de datos específicas cuando se aplican a conjuntos heterogéneos y variados. Este desafío limita la aplicabilidad clínica generalizada y representa un foco de investigación futura para potenciar la robustez y confiabilidad clínica de estas tecnologías.

Conclusiones

A partir del análisis de los resultados, se concluye que el avance hacia una inteligencia artificial robusta y confiable en radiología requiere trascender la optimización de métricas de precisión. Las conclusiones se fundamentan en tres pilares críticos:

La IA como Asistente de Diagnóstico, No como Reemplazo Autónomo

La evidencia revisada es contundente: las herramientas actuales de inteligencia artificial, incluidas las redes neuronales convolucionales para la detección de artefactos, deben conceptualizarse como asistentes de diagnóstico y no como sistemas autónomos. Los hallazgos, como los reportados en estudios sobre software automatizado en contextos clínicos reales, demuestran que incluso herramientas avanzadas pueden presentar tasas de error significativas frente a la complejidad y variabilidad de los casos reales. Por lo tanto, el principal aporte de estas tecnologías no radica en la autonomía, sino en su capacidad para alertar al radiólogo sobre imágenes potencialmente degradadas, acelerar los procesos de control de calidad y reducir la variabilidad subjetiva entre evaluadores, siempre bajo la supervisión experta y criterio final del especialista clínico.

La Generalización como Principal Desafío y Foco de la Investigación Futura

El análisis permite identificar que el principal vacío de investigación y el mayor obstáculo para la implementación no es lograr incrementos marginales de precisión en entornos controlados, sino resolver el problema fundamental de la generalización de los modelos. Los estudios futuros en este campo deberían priorizar:

El desarrollo y uso sistemático de bases de datos públicas, diversas y rigurosamente anotadas que reflejen fielmente la heterogeneidad de equipos, protocolos y poblaciones encontradas en la práctica clínica habitual.

La investigación en técnicas de aprendizaje robusto y adaptable que permitan a los modelos desempeñarse de manera consistente en diferentes entornos institucionales.

La validación clínica prospectiva, multicéntrica y rigurosa como nuevo estándar para reportar resultados, superando la validación exclusiva en conjuntos de datos ideales y homogéneos.

La Necesidad de un Enfoque Interdisciplinario y Metodológicamente Riguroso.

Finalmente, se concluye que la solución efectiva a estos desafíos no es puramente técnica. Se requiere una visión interdisciplinaria integral que combine de manera sinérgica el conocimiento de ingenieros, radiólogos, físicos médicos y expertos en ética para diseñar estudios clínicamente relevantes y socialmente responsables. Como aporte al avance del campo, se enfatiza la necesidad de un rigor metodológico superior en las investigaciones venideras: formular hipótesis que aborden problemas clínicos concretos, utilizar conjuntos de datos de validación verdaderamente independientes y reportar de manera transparente y completa no solo los éxitos del modelo, sino también sus limitaciones, fracasos y casos frontera. Solo mediante este enfoque crítico, colaborativo y éticamente guiado se podrá cerrar de manera efectiva la brecha existente entre el entorno de laboratorio y la aplicación confiable, segura y equitativa en la práctica clínica diaria.

Referencias bibliográficas

- A. Calzado y J. Geleijns. (2010). *Tomografía computarizada. Evolución, principios técnicos y aplicaciones*.
<https://revistadefisicamedica.es/index.php/rfm/article/view/115/115>
- American Association of Physicists in Medicine (AAPM). (2022). CT Metal Artifact Reduction (CT-MAR) Challenge Dataset. Recuperado de <https://www.aapm.org/GrandChallenge/CT-MAR/>
- Barrett, J. F., & Keat, N. (2004). Artifacts in CT: Recognition and avoidance. *RadioGraphics*, 24(6), 1679–1691. <https://doi.org/10.1148/rg.246045065>
- Bushberg, J. T., Seibert, J. A., Leidholdt, E. M., & Boone, J. M. (2011). *The Essential Physics of Medical Imaging* (3.^a ed.). Lippincott Williams & Wilkins.
- Carrizales, J. W., Flakus, M. J., Fairbourn, D., Shao, W., Gerard, S. E., Bayouth, J. E., Christensen, G. E., & Reinhardt, J. M. (2024). 4DCT *image artifact detection using deep learning*. *Medical Physics*, 52(2), 1096–1107.
<https://doi.org/10.1002/mp.17513>
- Dasegowda, G., Bizzo, B. C., Kaviani, P., Karout, L., Ebrahimian, S., Digumarthy, S. R., Neumark, N., Hillis, J. M., Kalra, M. K., & Dreyer, K. J. (2023). *Auto-Detection of Motion Artifacts on CT Pulmonary Angiograms with a Physician-Trained AI Algorithm*. *Diagnostics*, 13(4), 778. <https://doi.org/10.3390/diagnostics13040778>
- Fernandez L, (2025). Reducción de artefactos metálicos en tomografía computarizada: métodos clásicos e inteligencia artificial.
- Flores Maza, J. P., & González Martínez, L. (2025). Evaluación de métricas de calidad en el procesamiento de imágenes por IA. *Revista de Radiología Digital*, 12(1), 45-58.

- Franco López, A., & Fernández Pérez, C. (2018). *Manual de radiología clínica* (2.^a ed.). Elsevier.
- Galeano-Galeano, A., et al. (2021). Avances en reconstrucción iterativa para la reducción de dosis en TC. *Anales de Radiología México*, 20(3), 112-124.
- Goodfellow, I., et al. (2014). Generative Adversarial Nets. *Advances in Neural Information Processing Systems*, 27.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *CVPR*, 770-778.
- Hernández, J., & Suárez, D. (2023). *Aplicación de redes neuronales convolucionales para la detección de artefactos metálicos en tomografía computarizada*. *Revista Colombiana de Computación*.
<https://repositorio.upch.edu.pe/handle/20.500.12866/17457>
- J., Quan, G., & Li, Z. (2021). *A deep learning method for eliminating head motion artifacts in computed tomography*. *Medical Physics*, 49(1), 411–419.
<https://doi.org/10.1002/mp.15354>
- Kalender, W. A. (2021). *Computed Tomography: Fundamentals, System Technology, Image Quality, Applications* (4.^a ed.). Publicis.
- Kumschier, T., Thalhammer, J., Schmid, C., Haeusele, J., Koehler, T., Pfeiffer, F., Lasser, T., & Schaff, F. (2024). *Streak artefact removal in x-ray dark-field computed tomography using a convolutional neural network*. *Medical Physics*, 51(10), 7404–7414. <https://doi.org/10.1002/mp.17305>
- Litjens, G., et al. (2017). *A survey on deep learning in medical image analysis*. *Medical Image Analysis*, 42, 60–88.

Martín Cuartero, J., et al. (2018). *Guía práctica para la identificación de artefactos en TC multicorte. Seram, 1-15.*

P. Sartori et al. (2015). *Artefactos y artificios frecuentes en tomografía computada.*

<https://www.redalyc.org/articulo.oa?id=382543178003>

P. Sharma, «*Applications of Convolutional Neural Networks (CNN)*», 2021.

<https://www.analyticsvidhya.com/blog/2021/10/applications-of-convolutional-neural-networkscnn/> (accedido 14 de marzo de 2023).

Pineda, R., & López, C. (2023). *Inteligencia artificial aplicada al control de calidad en imágenes médicas: detección automática de artefactos en tomografía computarizada. Revista Iberoamericana de Tecnología en Salud.*

Redacción KeepCoding, «*Arquitectura típica de una red neuronal convolucional*», 6 de enero de 2023. <https://keepcoding.io/blog/arquitectura-tipica-red-neuronal-convolucional/> (accedido 6 de marzo de 2023).

Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. *MICCAI*, 234–241.

Sartori, P., et al. (2015). Artefactos en Tomografía Computada: Clasificación y Enfoque Clínico. *Revista Argentina de Radiología*, 79(4), 199-204.

SAS. (2018, 27 septiembre). *Inteligencia Artificial: Qué es y Por Qué Importa.*

https://www.sas.com/es_mx/insights/analytics/what-is-artificial-intelligence.html

Talamantes Román, M. (2024). *Inteligencia artificial aplicada al pre-procesamiento de señales biomédicas.* Editorial Universitaria.

Wang, G., Ye, J. C., Mueller, K., & Fessler, J. A. (2020). *Image reconstruction is a new frontier of machine learning. IEEE Transactions on Medical Imaging*, <https://doi.org/10.1109/TMI.2020.2977954>

Zhou, S. K., et al. (2020). *A Review of Deep Learning in Medical Imaging: Imaging Traits, Challenges, and Prospects. Proceedings of the IEEE*, 108(1), 125-154.