

**Evaluación de prototipos de software para la detección y corrección automática de artefactos de movimiento en tomografía de cráneo simple frente a métodos manuales de corrección en tomografía computarizada**

Astrid Carolina Agamez Pitalua

Danielle Cabuya Silva

Ferney León Torrijos

Natalia Pérez Galindo

Rosa Adriana Aya Amórtegui

Asesor

Robert Andrés Fuentes Niño

Universidad Nacional Abierta y a Distancia UNAD

Escuela de Ciencias de la Salud ECISA

Tecnología en Radiología e Imágenes Diagnósticas

2025

## **Agradecimientos**

En primer lugar, a Dios quien nos da la sabiduría y la guía para cumplir con los sueños y objetivos en nuestra vida llenos de retos, circunstancias, altibajos y oportunidades.

Queremos expresar nuestro agradecimiento a la Universidad Nacional Abierta y a Distancia (UNAD) y a la Escuela de Ciencias de la Salud ECISA por el apoyo brindado para la realización de este proyecto.

Agradecemos especialmente a nuestro asesor Robert Andrés Fuentes Niño, por su acompañamiento constante, guía experta y motivación durante todas las etapas de la investigación, aportando valiosos conocimientos y orientaciones que enriquecieron profundamente nuestro trabajo.

A nuestro equipo de trabajo Astrid Carolina Agamez Pitalua, Danielle Cabuya Silva, Ferney León Torrijos, Natalia Pérez Galindo, Rosa Adriana Aya Amórtegui por la constancia, el esfuerzo dado durante cada una de las fases para la construcción de este proyecto.

Finalmente, agradecemos a nuestras familias y amigos por su apoyo incondicional, ánimo y comprensión durante el proceso investigativo, así como a todos los autores y desarrolladores cuyas investigaciones y tecnologías fueron bases fundamentales para este estudio.

## Resumen

La tomografía computarizada de cráneo simple es fundamental para el diagnóstico neurológico; sin embargo, la calidad de las imágenes puede verse comprometida por artefactos de movimiento generados por desplazamientos involuntarios del paciente. Estos artefactos disminuyen la nitidez diagnóstica y pueden provocar repeticiones del estudio, mayor exposición a radiación y retrasos en la atención. Tradicionalmente, su corrección ha sido manual, un proceso dependiente del criterio del especialista y susceptible a variabilidad.

Este trabajo presenta una revisión sobre los principales factores que generan artefactos de movimiento en tomografía, los tipos de distorsiones asociados y las soluciones automáticas en desarrollo. Se analizan prototipos de software basados en algoritmos de procesamiento digital e inteligencia artificial, orientados a detectar y corregir estos artefactos sin repetir la adquisición. Asimismo, se revisan estudios que reportan mejoras en parámetros como relación señal-ruido, similitud estructural y reducción de errores de reconstrucción.

Metodológicamente, el documento se estructura mediante una revisión teórica y analítica de literatura científica reciente, complementada con el análisis comparativo entre métodos automáticos y manuales de corrección dentro de la tomografía computarizada. Los resultados de la revisión muestran que las técnicas automáticas presentan un desempeño superior o equivalente al método manual en calidad de imagen y eficiencia. Se concluye que estos sistemas representan una alternativa prometedora para optimizar el diagnóstico y el flujo de trabajo clínico, aunque aún requieren validación más amplia para su implementación generalizada.

**Palabras clave:** artefactos de movimiento, tomografía computarizada, corrección automática, inteligencia artificial en radiología, calidad diagnóstica.

## Abstract

Plain cranial computed tomography is essential for neurological diagnosis; however, image quality can be compromised by motion artifacts generated by involuntary patient movements. These artifacts reduce diagnostic sharpness and may lead to repeated scans, increased radiation exposure, and delays in patient care. Traditionally, their correction has been performed manually, a process dependent on the specialist's judgment and subject to considerable variability.

This work presents a review of the main factors that generate motion artifacts in computed tomography, the types of distortions associated with them, and the automated solutions currently under development. It analyzes software prototypes based on digital image processing and artificial intelligence algorithms designed to detect and correct these artifacts without requiring repeated acquisitions. Additionally, studies reporting improvements in parameters such as signal-to-noise ratio, structural similarity, and reductions in reconstruction errors are examined.

Methodologically, the document is structured through a theoretical and analytical review of recent scientific literature, complemented by a comparative analysis of automatic and manual correction methods within computed tomography. The results of the review indicate that automatic techniques demonstrate performance equal to or superior to manual correction in terms of image quality and efficiency. It is concluded that these systems represent a promising alternative for optimizing diagnostic accuracy and clinical workflow, although broader validation is still required for widespread implementation.

**Keywords:** motion artifacts, computed tomography, automatic correction, artificial intelligence in radiology, diagnostic quality.

## Tabla de Contenido

Introducción .....	11
Planteamiento del problema.....	14
Justificación .....	16
Objetivos.....	19
Objetivo General.....	19
Objetivos Específicos .....	19
Marco Teórico.....	20
Generalidades en Radiología.....	20
Artefactos de Movimiento en TC Craneal: Causas, Clasificación y Métodos de Corrección...	20
Conceptos Fundamentales .....	23
Unidades Hounsfield .....	23
Coeficiente de Atenuación.....	23
Tomografía Computada.....	25
¿Que son Artefactos?.....	25
Basados en la Física.....	25
Endurecimiento del Haz.....	25
Artefacto de Volumen Parcial.....	26
Artefacto de Déficit de Fotones.....	27
Basados en el Paciente.....	28
Objetos Metálicos .....	28
Artefacto por Movimiento .....	28
Proyección Incompleta.....	29

Artefactos por Equipo.....	29
Anillo .....	29
Propios de Equipos Helicoidales y Multicorte .....	30
Adquisición Helicoidal en el Plano Axial .....	30
Haz en Cono (Cone Beam).....	30
Reconstrucción Multiplanar y en 3D.....	30
Escalón.....	30
Cebra .....	30
Fundamentos de los Artefactos de Movimiento en Tomografía Computarizada Craneal .....	31
Evolución de los Métodos de Corrección Automática .....	35
Enfoques Tradicionales vs. Inteligencia Artificial .....	35
Arquitecturas de Redes Neuronales Especializadas .....	35
Metodologías Avanzadas de Simulación y Entrenamiento .....	37
Generación de Datos Sintéticos .....	37
Modelos de Difusión Condicionales.....	39
Técnicas de Reconstrucción Especializada .....	39
Reconstrucción de Ángulo Parcial (PAR) .....	39
Estudios Multicéntricos y Validación Real .....	40
Impacto en Flujos de Trabajo Radiológicos .....	40
Perspectivas Futuras y Desafíos Tecnológicos.....	41
Algoritmos de Corrección de Movimiento .....	42
Aumento de Resolución y Mejora de Contraste .....	43
Reconstrucción Iterativa y Modelos Probabilísticos .....	43

Filtrado y Realce de Bordes en Espacio de Imagen .....	43
Corrección de Ganancia y Calibración de Gantry .....	43
Antecedentes Empíricos .....	45
Concepto Básico de Difusión Condicional para la Corrección de Artefactos de Movimiento .	49
Modelo de Difusión Condicional para la Corrección Del Movimiento .....	49
Ecualización del Histograma .....	50
Evaluaciones Cuantitativas.....	51
Estudio de Simulación con Datos Fijos de Tomografía Computarizada .....	51
Efectos de Diferentes Tipos de Movimiento en los Artefactos de Tomografía Computarizada	
Craneal.....	52
Marco Metodológico.....	60
Enfoque Cualitativo .....	60
Enfoque Descriptivo .....	60
Obtención De Datos.....	61
Criterios de Inclusión.....	61
Limitación del Estudio.....	61
Análisis de Datos .....	62
Parámetros Legales.....	62
Resultados.....	63
Conclusiones.....	78
Referencias Bibliográficas .....	82

## Lista de Figuras

<b>Figura 1</b> <i>Escala de unidades Hounsfield</i> .....	24
<b>Figura 2</b> <i>Valores en unidades Hounsfield de los órganos</i> .....	24
<b>Figura 3</b> <i>TC de cerebro, corte axial</i> .....	26
<b>Figura 4</b> <i>TC de cerebro, corte axial</i> .....	27
<b>Figura 5</b> <i>TC de hombro, corte axial</i> .....	27
<b>Figura 6</b> <i>TC de cadera y columna, corte axial</i> .....	28
<b>Figura 7</b> <i>TC de cráneo, corte axial</i> .....	28
<b>Figura 8</b> <i>TC de tórax y de abdomen, corte axial</i> .....	29
<b>Figura 9</b> <i>TC de tórax con corte axial, imagen de control o de calibración</i> .....	29
<b>Figura 10</b> <i>TC de cráneo, ventana ósea, corte sagital</i> .....	30
<b>Figura 11</b> <i>Imágenes clínicas con artefactos de movimiento</i> .....	32
<b>Figura 12</b> <i>Artefactos por movimiento de cráneo en TC</i> .....	34
<b>Figura 13</b> <i>Artefactos y artificios frecuentes en tomografía computada</i> .....	34
<b>Figura 14</b> <i>Estructura de red neuronal propuesta</i> .....	36
<b>Figura 15</b> <i>Esquema de simulación de movimiento</i> .....	38
<b>Figura 16</b> <i>TC de cráneo, ventana ósea y blanda, corte axial</i> .....	44
<b>Figura 17</b> <i>Comparativa de imágenes con presencia de artefacto por movimiento vs repetición de escáner sin presencia de movimiento</i> .....	44
<b>Figura 18</b> <i>Marco general de HM-EDM</i> .....	49
<b>Figura 19</b> <i>Ecualización del histograma</i> .....	51
<b>Figura 20</b> <i>Los artefactos simulados en diferentes patrones de movimiento</i> .....	53
<b>Figura 21</b> <i>Comparación de los resultados de corrección de movimiento entre diferentes redes</i>	54

<b>Figura 22</b> <i>Corrección de artefactos en imágenes clínicas</i> .....	55
<b>Figura 23</b> <i>Correcciones de movimientos en imágenes de lesiones</i> .....	56
<b>Figura 24</b> <i>Corrección de movimiento en imagen clínicas de reconstrucción multiplanar (MPR)</i> .....	57
<b>Figura 25</b> <i>Ejemplos representativos del estudio de simulación</i> .....	58
<b>Figura 26</b> <i>La clasificación binaria del modelo de IA</i> .....	64
<b>Figura 27</b> <i>Comparativa de unidades Hounsfield en imagen con presencia de artefactos de movimiento</i> .....	65
<b>Figura 28</b> <i>Comparación de resultados de corrección de movimientos en diferentes redes</i> .....	68
<b>Figura 29</b> <i>Incremento en métricas cuantitativas de calidad de imagen y comparación AUC calidad subjetiva</i> .....	69
<b>Figura 30</b> <i>Ejemplos representativos del estudio de simulación</i> .....	71

### Lista de Tablas

<b>Tabla 1</b> <i>Comparación cuantitativa entre diferentes redes</i> .....	55
<b>Tabla 2</b> <i>Resultados del estudio de simulación</i> .....	58
<b>Tabla 3</b> <i>Comparativa de imagen en tomografía con y sin presencia de artefactos</i> .....	66
<b>Tabla 4</b> <i>Resultados del estudio de simulación</i> .....	70
<b>Tabla 5</b> <i>Análisis de resultados</i> .....	74
<b>Tabla 6</b> <i>Desafíos y soluciones</i> .....	80

## Introducción

La tomografía computarizada de cráneo simple es una herramienta indispensable para el diagnóstico en el área de neurología y neurocirugía, al generar imágenes detalladas del sistema nervioso central que favorecen el diagnóstico, seguimiento y manejo de diversas patologías intracraneales (Subias & Jerez, 2021) La calidad de las imágenes adquiridas por medio de la tomografía es decisiva para confirmar diagnósticos concisos y adecuados, fundamentales para la toma de decisiones clínicas. Sin embargo, uno de los mayores problemas que perjudican la calidad de las imágenes en tomografía craneal es la existencia de artefactos de movimiento, generados por los movimientos involuntarios de los pacientes durante la obtención de las imágenes, constituyendo el tipo de artefacto más común en los departamentos de tomografía, alcanzando una prevalencia del 73 % en tomografía cerebral (Dasegowda et al., 2023).

Estos artefactos crean distorsiones significativas en las imágenes, comprometen la resolución espacial y obstaculizan la interpretación de la imagen radiológica, induciendo a errores diagnósticos y al aumento de repeticiones del estudio. Esta problemática acarrea el aumento de exposición del paciente a radiación ionizante y a su vez a elevados costos clínicos por ende a la ineficiencia de los recursos hospitalarios (Caicedo et al., 2024). En Colombia, a pesar de no tener cifras exactas, se estima que un porcentaje de repeticiones significativas en tomografías se deben a la deficiencia en la calidad de las imágenes debido a los artefactos de movimiento, lo que figura en la problemática relevante para la seguridad del paciente y la gestión clínica, aunque estudios preliminares en hospitales universitarios de Bogotá sugieren que la repetición de tomografía relacionada con artefactos o mala calidad puede alcanzar entre el 20% y 25% de los estudios anuales (Contraloría de Bogotá, 2024). Para el año 2024 el costo de una repetición de tomografía computarizada depende del tipo de institución y el convenio que tenga

la misma, pero se puede decir que un precio base por tomografía es de \$180.000 a 280.000 pesos colombianos, Este valor corresponde a la realización del estudio de tomografía de cráneo simple por primera y su repetición tiene el mismo costo.

Las correcciones por artefactos de movimiento han dependido de las intervenciones manuales del radiólogo, que debe reconocer visualmente las alteraciones en las imágenes y solicitar repeticiones del estudio. Este procedimiento es gradual, subjetivo y costoso (Cifuentes et al., 2024). No obstante, los avances tecnológicos en algoritmos de IA (Inteligencia Artificial), procesamiento digital y aprendizaje profundo han fomentado el desarrollo de prototipos de software que proporcionen la detección y corrección automatizada de artefactos de movimiento. Estas herramientas brindan la posibilidad de optimizar la calidad diagnóstica de las imágenes sin necesidad de repetir la adquisición, reduciendo la exposición a la radiación, disminuyendo costos y mejorando el flujo de trabajo clínico.

Los sistemas automatizados fundamentados en redes neuronales convolucionales y modelos de difusión condicional han manifestado efectos positivos al superar las limitaciones de los métodos manuales en parametrización objetivos de la calidad como la relación señal-ruido (SNR), el índice de similitud estructural (SSIM) y la reducción de errores de reconstrucción (Álvarez et al., 2024). A pesar de ello, estos avances requieren validación en diversas instituciones clínicas, análisis de impacto operativo y aprobación por parte de los profesionales de la salud antes de su inclusión clínica general (Gutiérrez & Torres, 2022).

Considerando esto, el objetivo de este estudio es evaluar comparativamente la efectividad, replicabilidad y seguridad de los prototipos de software para la detección y corrección automática de artefactos de movimiento en tomografía computarizada de cráneo, frente a los métodos manuales empleados (Agámez et al., 2025). Asimismo, se abordarán

metodologías innovadoras para simulación de movimientos y técnicas especializadas para la reconstrucción de imágenes que contribuyen a la mejora de la calidad diagnóstica. Se prevé que los resultados aporten pruebas concluyentes para la aceptación de estas tecnologías en las diferentes instituciones médicas de Colombia, para mejorar la exactitud diagnóstica, optimizar el flujo de trabajo clínico y garantizar la seguridad del paciente.

## Planteamiento del problema

La tomografía computarizada es una herramienta diagnóstica esencial en neurocirugía y neurología, que favorece el análisis detallado de estructuras intracraneales para la identificación y seguimiento de varias patologías. La calidad de las imágenes por tomografía computarizada suele verse afectada por artefactos de movimiento causados por los pacientes durante la adquisición de la imagen. Esto provoca distorsiones, disminución de resolución y lecturas incorrectas, lo cual perjudica la precisión en los diagnósticos y la seguridad del paciente.

Transcendentalmente, la corrección de estos artefactos se ha ejecutado mediante mecanismos manuales que repitan el estudio o la realización de intervenciones visuales y subjetivas por parte del radiólogo, para reducir los errores. Tales procedimientos significan una mayor exposición a radiación, además de un incremento en el uso de recursos hospitalarios y tiempo.

Según una investigación de Cifuentes et al., (2024), “los artefactos por movimiento constituyen un reto para la calidad diagnóstica en tomografía computarizada ya que deterioran la fiabilidad de los resultados y demandan más repeticiones, lo que afecta a la gestión clínica y a la seguridad del paciente” (p.18).

La aplicación clínica de estos prototipos se mide con evaluaciones comparativas mediante técnicas manuales tradicionales para confirmar su eficacia, reproducibilidad y seguridad. El empleo de modelos automáticos que se fundamentan en redes neuronales convolucionales ha mostrado, según Vakli et al., (2023), resultados preliminares alentadores cuando se trata de detectar y eliminar artefactos de movimiento, pero todavía necesita una validación más amplia en diversos escenarios clínicos.

Por lo anterior se plantea la siguiente pregunta: ¿Cuál es la eficacia de los prototipos de software para la detección y corrección automática de artefactos de movimiento en tomografía de cráneo simple, en comparación con los métodos manuales de corrección utilizados por profesionales en tomografía computarizada?

## Justificación

La tomografía computarizada de cráneo es una herramienta clave en neurología y neurocirugía, ya que permite obtener imágenes detalladas de las estructuras intracraneales, lo que facilita la identificación y seguimiento de diversas patologías (Subias & Jerez, 2021), sin embargo, la calidad y precisión de estas imágenes son esenciales para realizar un diagnóstico adecuado. Por ello, uno de los mayores desafíos en este campo son los artefactos de movimiento, causados por el movimiento involuntario del paciente durante el examen.

Estos artefactos afectan la calidad de las imágenes, dificultando su interpretación y en muchos casos, obligando a repetir los estudios, lo que aumenta la exposición del paciente a radiación y también incrementa los costos clínicos (Caicedo et al., 2024). Como mencionan los autores en su estudio, “Los artefactos de movimiento son anormalidades que alteran las estructuras anatómicas reales en la imagen, provocando errores diagnósticos y generando repeticiones innecesarias, con implicaciones clínicas y económicas desfavorables” (Caicedo et al., 2024, p. 15).

A la fecha, Bogotá no cuenta con un número exacto de repeticiones de tomografía de cráneo simple por la calidad o por los artefactos de movimiento, pero según un estudio de un hospital universitario de Bogotá, se registró en 2022 que el 8.98% de las tomografías en urgencias no estuvieron indicadas, siendo la tomografía de cráneo simple una de las de mayor prevalencia entre estas (70,77% de no indicadas), también se detectó que en un nivel general la repetición de las tomografías se relaciona con el artefacto o mala calidad, se considera que es cerca de un 20% a 25% de los estudios anuales.

Para el año 2024 el costo de una repetición de tomografía computarizada depende del tipo de institución y el convenio que tenga la misma, pero podemos decir que un precio base por

tomografía es de \$180.000 a 280.000 pesos colombianos, Este valor corresponde a la realización del estudio de tomografía de cráneo simple por primera y su repetición tiene el mismo costo.

Debemos tener cuenta que estos valores no son iguales en cada institución ya que dependen del convenio, tipo de equipo que se usa y la cobertura ya sea por aseguradora o régimen subsidiado.

Este proyecto de investigación tiene como objetivo abordar esta problemática mediante el análisis, a partir de la evidencia científica disponible, de la eficacia y las ventajas de los prototipos de software que emplean algoritmos automatizados para detectar y corregir artefactos de movimiento en tomografía de cráneo. Su relevancia radica en la posibilidad de mejorar la calidad diagnóstica, optimizar el uso de recursos clínicos y reducir la necesidad de repeticiones que incrementan la exposición a la radiación. Los avances recientes en tecnologías de corrección automatizada han mostrado resultados prometedores, lo que resalta la importancia de evaluar su desempeño y su potencial impacto en la práctica clínica.

Según Planmeca (2024), “las correcciones automáticas de movimientos en tomografía computarizada permiten obtener imágenes de alta calidad, reduciendo la necesidad de repetir el procedimiento, lo que optimiza tanto el tiempo de diagnóstico como la dosis de radiación”, este enfoque mejora la precisión de los diagnósticos y optimiza los recursos clínicos, reduce costos y lo más importante, mejora la seguridad del paciente.

La aplicabilidad de este proyecto es clara en el ámbito clínico, especialmente en hospitales y centros de salud que utilizan la tomografía computarizada como herramienta diagnóstica. Al implementar algoritmos automáticos para corregir artefactos de movimiento, se mejorará significativamente la precisión diagnóstica, a la vez que se optimiza el tiempo de trabajo clínico y se reduce el uso de recursos como la repetición de estudios y la exposición a

radiación. Además, los radiólogos podrán contar con imágenes más claras y confiables que facilitarán un proceso diagnóstico más eficiente.

Un aspecto relevante de este proyecto es el análisis de algoritmos avanzados de procesamiento digital, inteligencia artificial y aprendizaje profundo que permiten la corrección automática de artefactos de movimiento en tomografía de cráneo. La literatura revisada destaca tecnologías de corrección iterativa retrospectiva, como las desarrolladas por Canon Medical, las cuales “mejoran la calidad de las imágenes mediante algoritmos que ajustan la reconstrucción para suprimir los artefactos de movimiento, sin necesidad de equipos complementarios, integrándose eficazmente al flujo clínico” (Zhan et al., 2025). Esta evidencia sugiere que estas técnicas automáticas tienen ventajas sobre los métodos manuales tradicionales, que dependen de la intervención subjetiva del radiólogo y frecuentemente requieren la repetición del examen. El proyecto se centra en la revisión bibliográfica como herramienta principal para evaluar y comparar la eficacia de estas soluciones automatizadas frente a los enfoques manuales, destacando sus beneficios y limitaciones documentadas en la literatura científica.

En cuanto a la viabilidad, se cuenta con el respaldo de los avances tecnológicos recientes que facilitan la implementación de estos sistemas de corrección automatizada. Los prototipos de software basados en inteligencia artificial y procesamiento digital son efectivos para mejorar la calidad de las imágenes y su integración con los sistemas de tomografía computarizada existentes es cada vez más simple.

Es así como la investigación comparativa entre los métodos automáticos y manuales permitirá validar la eficacia, reproducibilidad y seguridad de estos prototipos, garantizando que su adopción sea una mejora significativa en los procesos diagnósticos y en la calidad de la atención al paciente.

## **Objetivos**

### **Objetivo General**

Analizar la eficacia de prototipos de software para la detección y corrección automática de artefactos de movimiento en tomografía de cráneo simple, comparándolos con los métodos manuales de corrección utilizados por profesionales en tomografía computarizada.

### **Objetivos Específicos**

Identificar los factores que contribuyen a la aparición de artefactos de movimiento en tomografía de cráneo, mediante la revisión y análisis de información teórica y empírica.

Describir los tipos de artefactos de movimiento que afectan la calidad de las imágenes en tomografía computarizada.

Evaluar la eficacia de prototipos de software para la detección y corrección automática de artefactos de movimiento en tomografía computarizada.

Analizar la calidad diagnóstica de las imágenes corregidas automática y manualmente, considerando parámetros objetivos como el nivel de ruido y resolución y subjetivos como la evaluación experta.

## **Marco Teórico**

### **Generalidades en Radiología**

La teórica específica de la radiología hace referencia al uso de radiación u otras tecnologías de imagenología como Tomografía, resonancia magnética, etc.) para diagnosticar o tratar enfermedades (NIH, s.f.). El Dr. Ramírez, hace mención al desarrollo tecnológico de la radiología, el cual ha sido sorprendente, debido a sus descubrimientos por varios investigadores, iniciando por el físico Wilhelm Conrado Röntgen, en 1895, quien descubrió los rayos X, a Henry Becquerel, Pierre y Marie Curie en 1896, por las contribuciones que hicieron en relación a la radioactividad, entre otras, el descubrimiento del radium (polonio, en honor del país de nacimiento de María Curie); a Godfrey Hounsfield y Alan Cormack, en 1979, por la invención de la tomografía computada, y a Paul Lauterbur y Raymond Damadian, en 2005, por sus contribuciones para el desarrollo de la resonancia magnética Ramírez (2019,p.8).

Ahora se estudiará a través de este marco teórico, como ha contribuido el avance tecnológico de la radiología para el diagnóstico y calidad de las imágenes.

### **Artefactos de Movimiento en TC Craneal: Causas, Clasificación y Métodos de Corrección**

En ese mismo contexto, las imágenes biomédicas son útiles para ayudar en el diagnóstico médico, seguimiento y evaluación progresiva de la enfermedad. La tomografía es una herramienta útil en el diagnóstico médico que proporciona imágenes detalladas anatómicas de las estructuras cerebrales especialmente en estudio de cráneo simple. Puede utilizarse para descartar hemorragias, tumores o anomalías estructurales. Sin embargo, puede verse comprometida la calidad de las imágenes por artefactos de movimiento, los cuales constituyen el tipo de artefacto más común en los departamentos de tomografía, alcanzando una prevalencia del 73% en tomografía cerebral (Dasegowda et al., 2023), 35% en tomografía de tórax (Dasegowda et al.,

2023), y representando la fuente más común de artefactos en tomografía cardíaca, pudiendo originarse por movimiento del paciente, movimiento cardíaco o respiratorio (Boas y Fleischmann, 2012).

La tomografía computarizada (TC) craneal es una herramienta fundamental en la práctica clínica moderna, ya que permite obtener imágenes anatómicas detalladas del cerebro y estructuras adyacentes con alta resolución espacial y contraste tisular. Este método es especialmente útil en el diagnóstico temprano de hemorragias, tumores, infartos cerebrales y malformaciones estructurales, así como en la planificación de intervenciones quirúrgicas y seguimiento de patologías neurológicas (Armiñana et al., 2023). La precisión de la TC craneal facilita la toma de decisiones médicas oportunas y contribuye significativamente a mejorar los resultados clínicos en situaciones de urgencia, como accidentes cerebrovasculares o traumatismos craneoencefálicos.

En tomografía computarizada, los artefactos se definen como distorsiones, errores o adiciones en la imagen que no corresponden con la anatomía real del paciente. Estas alteraciones pueden manifestarse como líneas, sombras, bandas, zonas borrosas o duplicaciones de estructuras, y surgen por múltiples causas, incluyendo factores físicos del equipo, características del paciente y limitaciones en los protocolos de adquisición (Boas y Fleischmann, 2012), indicando que se trata de un fenómeno artificial que altera la fidelidad de la imagen obtenida (Cifuentes et al., 2024).

El impacto de estos artefactos trasciende la calidad diagnóstica, generando consecuencias económicas sustanciales: aproximadamente el 20% de los estudios de imagen requieren readquisición debido a artefactos de movimiento, con costos asociados estimados en \$115,000 por escáner anualmente (Beljaards et al., 2024), sin considerar los costos indirectos relacionados

con el tiempo adicional del personal, retrasos diagnósticos y prolongación de estancias hospitalarias. En escenarios neurológicos críticos, particularmente en estudios de accidente cerebrovascular, los artefactos de movimiento ocurren en aproximadamente el 7% de los casos, correlacionándose significativamente con mayor edad del paciente y presencia de síntomas motores, reduciendo la precisión diagnóstica tanto de sistemas de inteligencia artificial como de radiólogos experimentados (Krogh et al., 2025).

La corrección de artefactos en tomografía computarizada es un proceso fundamental para garantizar la calidad diagnóstica de las imágenes. Tradicionalmente, este manejo se ha realizado de manera manual, mediante la intervención del radiólogo o técnico, ajustando parámetros de reconstrucción, repitiendo adquisiciones o aplicando filtros específicos para minimizar distorsiones visibles en las imágenes (Cifuentes et al., 2024).

En contraste, los métodos automáticos basados en software han avanzado significativamente en los últimos años. Las técnicas modernas utilizan algoritmos de procesamiento digital, inteligencia artificial (IA) y aprendizaje profundo, capaces de detectar y corregir artefactos sin necesidad de repetir la adquisición (Amirian et al., 2023).

Por ejemplo, redes neuronales convolucionales (CNN) han demostrado ser eficaces en la identificación de patrones de artefactos y la reconstrucción de imágenes de alta calidad, incluso en tomografías de baja dosis o con movimientos complejos del paciente. Estas herramientas permiten mejorar parámetros críticos como la relación señal-ruido, la similitud estructural y la precisión diagnóstica, integrándose de manera eficiente al flujo clínico sin requerir cambios en el equipo físico (Amirian et al., 2023).

## **Conceptos Fundamentales**


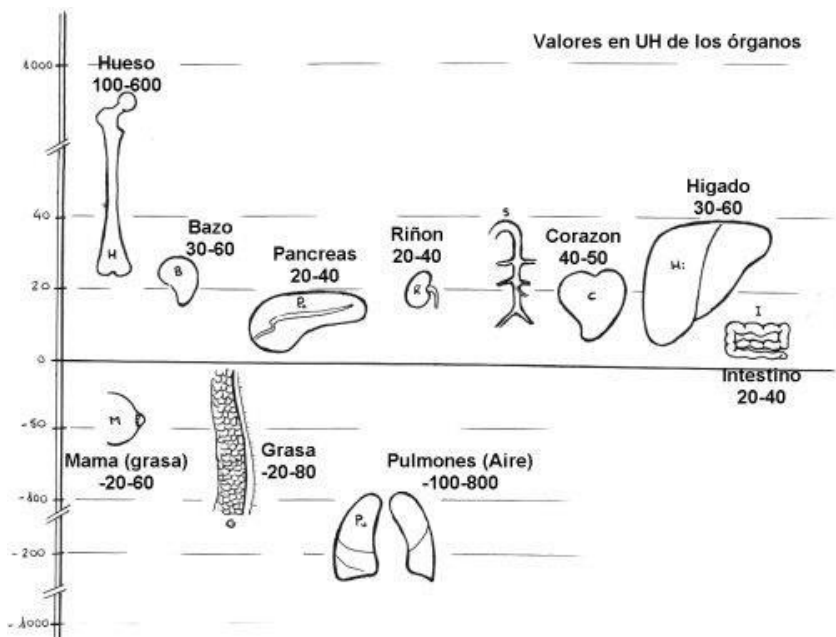
### ***Unidades Hounsfield***

Armimaña et al., (2023) indican que las unidades Hounsfield se emplean en los estudios de tomografía computarizada para medir de forma cuantitativa la atenuación de las estructuras y órganos en el sujeto de estudio. Es una unidad estandarizada, para su evaluación debe considerarse los distintos factores que inciden en su valor cuando se obtienen con diferentes protocolos, parámetros y equipos de tomografía. El principal factor que afecta al valor de esta medida es la energía del haz de rayos X empleado en la adquisición de las imágenes.

### ***Coefficiente de Atenuación***

Armimaña et al., (2023) las imágenes de tomografía representan la reconstrucción del coeficiente de atenuación de los tejidos al paso de los rayos X. Este valor se obtiene a partir de la medida de la radiación emitida que logra atravesar los tejidos y llegar a los detectores. La diferencia entre la intensidad de la radiación emitida y la que llega al detector depende del coeficiente de atenuación y del grosor del material interpuesto en el trayecto del haz.

En los inicios de la tomografía se propuso una escala representativa de los posibles valores de atenuación, desde el aire (-1000) cuya atenuación es despreciable, con el agua valor 0 y extendiéndose hasta infinito.

**Figura 1***Escala de unidades Hounsfield**Nota. Tomado de unidades Hounsfield (s.f.)***Figura 2***Valores en unidades Hounsfield de los órganos**Nota. Tomado de unidades Hounsfield (s.f.)*

## **Tomografía Computada**

Sartori et al., (2025) los artificios ocurren como resultado de la interacción entre el tomógrafo y el paciente. Por lo tanto, se dividen según y dependiendo de la naturaleza se observan como rayas, anillos, ruidos, bandas blancas y negras superpuestas.

### ***¿Que son Artefactos?***

Según Sartori et al., (2015) la define como una distorsión, adición o error en una imagen que no tiene correlación con la región anatómica estudiada. Se deriva de las palabras latinas *artis* (artificial) y *actum* (efecto), y refiere a un efecto artificial que altera la calidad y fidelidad de una imagen, llegando a encubrir una patología o crear un hallazgo falso. Por lo tanto, los artefactos tienen diversas causas:

### ***Basados en la Física***

**Endurecimiento del Haz.** González et al., (2014) Se refiere cuando el haz de rayos X atraviesa un objeto es filtrado y su energía media aumenta debido a que los fotones menos energéticos son absorbidos más rápidamente. Por lo tanto, él haz tendrá un bajo coeficiente lineal de atenuación falso y un bajo número de tomografía falso. Se observa en forma de bandas oscuras o rayas brillantes entre dos objetos.

**Figura 3**

*TC de cerebro, corte axial*




*Nota.* Artefacto (flecha) por endurecimiento del haz de rayos, se visualizan líneas intercaladas que pueden ser hiperdensas o hipodensas. Tomada de *Artefactos y artificios frecuentes en TC y RM* (p. 194). por Sartori et al., 2015., *Revista Argentina De Radiología*.

**Artefacto de Volumen Parcial.** González et al., (2014) Se genera cuando un objeto denso alejado del eje de rotación es barrido parcialmente por este en una parte del giro y no es captado, debido a la divergencia del haz, cuando el tubo pasa por el lado contrario. Por lo que produce artefactos sombreados.

**Figura 4**

*TC de cerebro, corte axial*




*Nota.* Se aprecian bandas lineales hipo e hiperdensas, originadas en los peñascos y la protuberancia occipital interna por un artefacto de volumen parcial promedio (flechas). Tomada de *Artefactos y artificios frecuentes en TC y RM* (p.196). Por Sartori et al., 2015., *Revista Argentina De Radiología*.

**Artefacto de Déficit de Fotones.** González et al. (2014) Suele causar artefactos rayados en la dirección de las partes anatómicas más anchas, como caderas, corazón y hombros.

**Figura 5**

*TC de hombro, corte axial*




*Nota.* En la imagen se visualiza un rayado a la altura de la cintura escapular (hombros). Tomada de *Técnicas de tomografía computarizada y ecografía* (p.129). Por González et al., 2014.

### ***Basados en el Paciente***

**Objetos Metálicos.** González et al. (2014) Objetos de alta atenuación en la tomografía producen artefactos –bandas oscuras y brillantes

#### **Figura 6**

*TC de cadera y columna, corte axial*




*Nota.* Se visualiza en la imagen A y B el artefacto producido por el metal de una prótesis de cadera (A), y de los tornillos en una artrodesis de columna (B). Tomada de *Técnicas de tomografía computarizada y ecografía* (p.130). Por González et al., 2014.

**Artefacto por Movimiento.** González et al. (2014) Provoca imágenes distorsionadas y borrosas o bandas brillantes y oscuras.

#### **Figura 7**

*TC de cráneo, corte axial*




*Nota.* Se observa la deficiente calidad de imagen producida por el movimiento del paciente. Tomada de *Técnicas de tomografía computarizada y ecografía* (p.130). Por González et al., 2014.

**Proyección Incompleta.** González et al. (2014) Se genera cuando parte del paciente se queda por fuera del campo de visión escaneado.

### Figura 8

*TC de tórax y de abdomen, corte axial*




*Nota.* Se visualiza en la imagen (A) (flecha amarilla) como los brazos del paciente se sitúan fuera del SFOV y generan artefactos en forma de rayas. (B) El tamaño del paciente hace que una parte del abdomen salga del SFOV y genere artefactos. Tomada de *Técnicas de tomografía computarizada y ecografía* (p.131). Por González et al., 2014.

### Artefactos por Equipo

**Anillo.** González et al. (2014) Se da en equipos de 3ra generación. Se produce por el fallo de uno o varios detectores o por calibración incorrecta.

### Figura 9

*TC de tórax con corte axial, imagen de control o de calibración*



*Nota.* (A) Se visualiza un anillo provocado por la rotura de una tarjeta encargada de procesar la imagen de varias filas de detectores. (B) Corte en una fantoma donde se observa varios anillos. Tomada de *Técnicas de tomografía computarizada y ecografía* (p.132). Por González et al., 2014.

## Propios de Equipos Helicoidales y Multicorte

### *Adquisición Helicoidal en el Plano Axial*

González et al., (2014) Se genera cuando las estructuras anatómicas cambian rápidamente en el eje z y los datos recogidos son insuficientes.

### *Haz en Cono (Cone Beam)*

González et al. (2014) A medida que aumenta el tamaño de la matriz de detectores es necesario el uso de haz más ancho, esto es, menos colimado.

### *Reconstrucción Multiplanar y en 3D*

**Escalón.** González et al. (2014) Se da porque el vóxel no suele ser un cubo, no es isométrico, y la resolución espacial es peor en el eje Z.

## Figura 10

*TC de cráneo, ventana ósea, corte sagital*



*Nota.* Se visualiza reconstrucción MPR con artefacto de escalón al usar vóxel no isométrico. Tomada de *Técnicas de tomografía computarizada y ecografía* (p.133). Por González et al., 2014.

**Cebra.** González et al. (2014) Bandas apenas visibles en reconstrucciones MPR y 3D. Se visualiza en los extremos de la imagen.

## **Fundamentos de los Artefactos de Movimiento en Tomografía Computarizada Craneal**


Los artefactos de movimiento en tomografía computarizada (TC) craneal representan uno de los principales desafíos técnicos en radiología diagnóstica, causando discontinuidades significativas en los datos de adquisición que resultan en degradación sustancial de la calidad de imagen. Su et al., (2022) refiere que se les indica a los pacientes que permanezcan inmóviles durante el estudio de tomografía. Sin embargo, en ciertas circunstancias clínicas, como lesiones nerviosas o hemorragias cerebrales, puede resultar difícil evitar el movimiento. Además, el problema puede agravarse por movimientos involuntarios del soporte del paciente, como un soporte vibratorio.

El movimiento inesperado durante las tomografías provoca discontinuidades en los datos, lo que a su vez introduce artefactos de rayas o estrellas originándose a partir de estructuras anatómicas con un alto gradiente.

Por lo que establecen que estos artefactos provocan una pérdida considerable en la confiabilidad diagnóstica, especialmente cuando involucran movimientos complejos como rotación, traslación y oscilación, los cuales pueden comprometer seriamente la interpretación radiológica. El impacto clínico de estos artefactos se traduce directamente en la necesidad de repetir estudios, aumentando la exposición a radiación y los costos asociados al proceso diagnóstico.

## Figura 11

### *Imágenes clínicas con artefactos de movimiento*



*Nota.* Se muestra artefactos inducidos por el movimiento en las imágenes de la cabeza se originan principalmente en el cráneo. Tomada de *A Deep Learning method for eliminating head motion artifacts in computed tomography* (p. 412). Por Su et al., 2022., *Medical Physics*.

Su et al., (2022) proponen ideas para la corrección de artefactos de movimiento. Una de ellas es la reducción en el tiempo de escaneo el cual puede congelar el movimiento; sin embargo, este método disminuye la relación señal/ruido (SNR) en comparación con el escaneo convencional. La ponderación de vistas es una técnica común que asigna factores de ponderación menores a las vistas con discontinuidades.

Este método puede corregir los artefactos hasta cierto punto. Dado que el patrón de movimiento suele ser variable, no se dispone de un conjunto de factores de ponderación. Un método de software utiliza métrica de artefactos de movimiento (MAM), como la variación total, para la eliminación del movimiento. En este método, mediante la estimación del movimiento, las imágenes se actualizan mediante reconstrucción con corrección de movimiento.

A continuación, se estima el movimiento utilizando las imágenes reconstruidas actualizadas. Los procesos se repiten alternativamente hasta que se minimiza el valor MAM de la imagen. Otro método que cabe mencionar es un esquema de estimación y compensación de movimiento basado en proyección. Este método se basa en la reconstrucción de la imagen

mediante el algoritmo de maximización de la expectativa por subconjuntos ordenados. Los métodos iterativos presentan una alta complejidad computacional y su función de penalización es difícil de diseñar para lograr un buen rendimiento.


Su et al., (2022) indican que las redes neuronales han aportado gran beneficio al procesamiento de imágenes médicas. Las CNN pueden aprender de forma eficiente características de alto nivel a partir de regiones de píxeles mediante un marco jerárquico. Ya existen numerosos artículos sobre análisis de imágenes basados en CNN, como la clasificación de lesiones, las mejoras de imágenes y la segmentación de órganos. Los enfoques basados en CNN también se han aplicado a la reconstrucción de imágenes para TC de baja dosis, incluyendo la TC con baja corriente del tubo y la TC con vistas dispersas.

Según Martin et al., (2004) estos artefactos son frecuentes en la región craneal. La cabeza es una de las zonas anatómicas con más movilidad cuando el paciente se encuentra acostado en la mesa del tomógrafo. A menudo los estudios de tomografía se realizan en pacientes ancianos, con demencia, con enfermedades que generan temblores tipo Parkinson, o que tienden a fatigarse., usualmente el movimiento hace que el estudio sea deficiente o no valorable.

Las regiones encefálicas con mayor contacto con hueso son las que más se artefactan y son menos valorables, especialmente las fosas temporales y posteriores. Las estructuras óseas pequeñas a menudo se verán artefactadas como el caso de las celdillas etmoidales, peñascos, etc.

## Figura 12


### *Artefactos por movimiento de cráneo en TC*



*Nota.* Imágenes axiales de TC craneal en ventana de hueso (A) y de cerebro (B). Los artefactos por movimiento son más evidentes en el hueso de las celdillas etmoidales y de las fosas nasales (flechas), y a nivel parenquimatoso en las fosas temporales (punta de flecha). Tomada de *Eppur si muove: Artefactos por movimiento en TC. Conocerlos y evitarlos* (p.6). Por Martin et al., 2004., *SERAM*.

## Figura 13

### *Artefactos y artificios frecuentes en tomografía computada*



*Nota.* TC de macizo craneofacial, en ventana ósea, corte axial: se observa una distorsión de la anatomía normal que genera la apariencia de fantasmas o imágenes que se reiteran en forma difuminada. Corresponde a un artefacto por movimiento del paciente. Tomada de *Artefactos y artificios frecuentes en TC y RM* (p. 193). por Sartori et al., 2015., *Revista Argentina De Radiología*.

## **Evolución de los Métodos de Corrección Automática**

### ***Enfoques Tradicionales vs. Inteligencia Artificial***

La transición de métodos manuales hacia sistemas automatizados basados en inteligencia artificial ha marcado un paradigma fundamental en la corrección de artefactos de movimiento. Dasegowda et al., (2023) demuestran que los sistemas de IA pueden lograr una precisión del 94% de sensibilidad y 91% de especificidad en la detección automática de artefactos significativos, superando considerablemente la variabilidad inherente de los métodos manuales tradicionales que dependen completamente de la interpretación humana. Superioridad que se fundamenta en la capacidad de los algoritmos de aprendizaje automático para procesar grandes volúmenes de datos de manera consistente y objetiva, eliminando la subjetividad asociada a la evaluación visual directa.

Hace poco, la IA en especial las redes neuronales convolucionales, ha realizado de manera exitosa la detección automática y la corrección de artefactos en imágenes por tomografía. Estos prototipos distinguen patrones complejos, reconocen y corrigen artefactos de movimiento minuciosamente en relación con los manuales (Caicedo et al., 2024; Méndez et al., 2025).

### ***Arquitecturas de Redes Neuronales Especializadas***

La implementación de arquitecturas de redes neuronales convolucionales (CNN) específicamente diseñadas para la corrección de artefactos de movimiento ha demostrado resultados sobresalientes.


Su et al., (2022) desarrollaron una red neuronal 3D con campo receptivo amplio que logró reducir el error absoluto medio de  $178 \pm 33$  HU a  $37 \pm 9$  HU y aumentar el índice de similitud estructural (SSIM) de  $0.60 \pm 0.06$  a  $0.98 \pm 0.01$ , estableciendo nuevos estándares de referencia en la corrección automática de artefactos. Estas mejoras cuantitativas representan avances

significativos comparados con técnicas de reconstrucción convencionales como la retroproyección filtrada.

Su et al., (2022) la red para corregir artefactos inducidos por movimiento es una modificación de la U-Net. Introdujeron una ResNet en la capa intermedia de la U-Net. Las múltiples capas de agrupación en la U-Net garantizan un amplio campo de recepción, lo que contribuye a la extracción de artefactos de gran extensión. Sin embargo, la operación de agrupación en cascada puede provocar pérdida de resolución espacial, la cual no se puede recuperar completamente ni siquiera con operaciones de deconvolución. Por lo tanto, se aplica una rama ResNet adicional en la capa intermedia de la U-Net para conservar la resolución. La ResNet original es una operación de convolución en cascada con algunas conexiones de atajo para facilitar retro propagación del gradiente. La ausencia de una operación de submuestreo conserva la resolución, pero sacrifica el amplio campo de recepción. Para equilibrar la resolución y el campo de recepción, aplicamos una estructura de dilatación en la rama ResNet.

**Figura 14**

*Estructura de red neuronal propuesta*



*Nota.* Se visualizan recuadros grises en donde cada uno representa un mapa de características aprendido, y el recuadro blanco representa el mapa de características copiado. El número de canal de las características se encuentra en la parte superior del recuadro. Las flechas con diferentes orientaciones y estilos representan diferentes operaciones y se definen en la leyenda en la parte inferior derecha de la figura. Tomada de A Deep Learning method for eliminating head motion artifacts in computed tomography (p.414). por Su et al., 2022., *Medical Physics*.

Kang y Lee (2024) complementan estos hallazgos mediante su implementación de modelos U-Net optimizados, logrando mejoras de  $5.35\times$  en RMSE y  $1.51\times$  en PSNR utilizando conjuntos de datos basados en mapas residuales. Su metodología de simulación tridimensional en el espacio  $k$  permite generar grandes volúmenes de datos de entrenamiento sintéticos, superando las limitaciones de disponibilidad de datos pareados reales y evitando problemas de sobreajuste.

## **Metodologías Avanzadas de Simulación y Entrenamiento**

### ***Generación de Datos Sintéticos***


La creación de conjuntos de datos sintéticos mediante algoritmos de simulación de movimiento representa una innovación crucial en el entrenamiento de modelos de IA. Su et al. (2022) establecieron que la simulación de movimiento que considera rotación, traslación, oscilación y sus combinaciones permite entrenar redes neuronales sin depender de casos clínicos reales, resolviendo la escasez de datos pareados en radiología médica. Esta metodología ha demostrado ser particularmente efectiva para entrenar modelos CNN con pares de imágenes ideales que capturan la variabilidad real del movimiento del paciente.

Por lo tanto, Su et al. (2022) indican que el algoritmo de simulación de movimiento procesa datos geoméricamente de forma similar al proceso de adquisición durante una TC. El patrón de movimiento 3D del objeto se predefine antes de la adquisición virtual de datos. Para cada vista, el objeto se mueve con un pequeño ángulo o distancia, o una combinación de ambos.

Una proyección 3D directa sobre el objeto para obtener los datos de proyección. Se simula una rotación completa y se utiliza un algoritmo de reconstrucción adecuado para reconstruir las imágenes con los artefactos de movimiento simulados.

## Figura 15

### Esquema de simulación de movimiento



*Nota.* Se visualiza una pila de imágenes volumétricas de la cabeza, sin movimiento, como objetos escaneados. Tomada de A deep learning method for eliminating head motion artifacts in computed tomography (p.414). por Su et al., 2022., *Medical Physics*.

Su et al., (2022) Se realiza una proyección 3D directa sobre las imágenes volumétricas, vista por vista. Se aplican movimientos rígidos, incluyendo rotación, traslación y oscilaciones al objeto, cambiando la vista en cada paso. Tras adquirir los datos de proyección, en una rotación completa, se retro proyectan los datos para obtener las imágenes con movimiento simulado asociadas mediante una operación de retroproyección filtrada (FBP).

Durante una rotación completa, se recopilan datos de proyección en múltiples ángulos, lo que simula la adquisición típica de modalidades como la tomografía computarizada. Una vez obtenida toda la información, los autores emplean un proceso de retroproyección filtrada (FBP, por sus siglas en inglés) para reconstruir las imágenes afectadas por el movimiento. Esta retroproyección permite integrar los datos adquiridos en cada ángulo, generando así imágenes que reproducen fielmente el efecto del movimiento simulado. El enfoque presentado por Su et al. constituye una herramienta fundamental para estudiar cómo el movimiento impacta la calidad de imagen y para desarrollar estrategias de corrección más precisas y robustas.

Amirian et al., (2023) expandieron esta aproximación mediante la integración de datos sintéticos generados con tomografías 4D, campos vectoriales de deformación y señales de amplitud dependientes del tiempo, logrando mejoras de hasta +6.3 dB en PSNR y +0.19 en SSIM comparado con algoritmos de reconstrucción CBCT existentes. Su validación clínica demostró 74% de preferencia por parte de expertos clínicos, estableciendo la primera demostración clínica de que la inserción de redes neuronales profundas como complementos en la reconstrucción 3D produce mejoras significativas.

### ***Modelos de Difusión Condicionales***

Chen et al., (2025) introdujeron una aproximación revolucionaria mediante HeadMotion-EDM (HM-EDM), el primer modelo de corrección de artefactos basado en modelos de difusión condicionales para TC craneal. Metodología que supera las limitaciones de sobre suavizado de los métodos CNN tradicionales, utilizando el marco avanzado del Elucidated Diffusion Model (EDM) que integra mejoras críticas para acelerar el proceso de muestreo. La capacidad de procesar una TC craneal 3D completa en menos de 2 minutos usando hardware estándar, comparado con los aproximadamente 20 minutos requeridos por DDPM convencional, representa un avance significativo hacia la implementación clínica práctica.

### **Técnicas de Reconstrucción Especializada**

#### ***Reconstrucción de Ángulo Parcial (PAR)***

Chen et al., (2024) desarrollaron una metodología innovadora que utiliza reconstrucción de ángulo parcial (PAR) para estimar directamente el movimiento cefálico rígido de 6 grados de libertad. Su aproximación divide las proyecciones de 360° en 25 segmentos consecutivos, empleando redes neuronales convolucionales que modelan cada variable de movimiento usando B-splines con 5 puntos de control. Los resultados demuestran errores absolutos medios de 0.28-

0.45 mm o grados en estudios de simulación, estableciendo una precisión superior a métodos de estimación de movimiento tradicionales.

La integración del movimiento estimado en algoritmos de reconstrucción iterativa permite compensar efectivamente los artefactos, logrando reducciones del MAE de imagen de  $178 \pm 33 \text{HU}$  a  $37 \pm 9 \text{HU}$  y aumentos del SSIM de  $0.60 \pm 0.06$  a  $0.98 \pm 0.01$  en estudios controlados. Esta metodología representa un avance fundamental hacia la automatización completa del control de calidad en tomografía craneal.

### ***Estudios Multicéntricos y Validación Real***

La validación clínica de estos sistemas automatizados ha demostrado consistentemente su superioridad sobre métodos manuales tradicionales. Dasegowda et al. (2023) realizaron validación multicéntrica con 793 exámenes de CTPA de tres sitios médicos (dos cuaternarios y uno comunitario), donde 372 casos no presentaron artefactos y 421 tenían artefactos sustanciales. La clasificación binaria automatizada ("movimiento" vs "sin movimiento") logró 93% de precisión con un área bajo la curva ROC de 0.93, estableciendo la viabilidad práctica de implementación en entornos clínicos reales.

### ***Impacto en Flujos de Trabajo Radiológicos***

La implementación de sistemas de IA para corrección automática de artefactos representa una transformación fundamental en los flujos de trabajo radiológicos. Como establecen los análisis de automatización en radiología, estos sistemas permiten a los profesionales enfocar su expertise en casos complejos y toma de decisiones críticas, mientras que las tareas repetitivas de detección y corrección de artefactos son manejadas automáticamente. La capacidad de alertar inmediatamente sobre la presencia de artefactos significativos durante la adquisición permite la

repetición inmediata del estudio con mejores instrucciones al paciente, optimizando los resultados diagnósticos.

### **Perspectivas Futuras y Desafíos Tecnológicos**

Los avances recientes en modelos de difusión y arquitecturas de Transformers sugieren un potencial significativo para mejoras adicionales en la corrección automática de artefactos. La integración de métodos híbridos que combinan física y aprendizaje profundo promete soluciones más robustas y generalizables, mientras que el desarrollo de sistemas de procesamiento en tiempo real facilitará la implementación rutinaria en departamentos de radiología. La evolución hacia sistemas automatizados de control de calidad es el siguiente paso hacia la optimización integral de la tomografía computarizada craneal, donde detectar, corregir y validar artefactos de movimiento será transparente para el flujo de trabajo clínico.

Por consiguiente, Philips Healthcare, la compañía ha incorporado tecnologías como iPatient con iDose y O-MAR en sus sistemas de TC, que permiten la reducción de ruido y artefactos, incluyendo aquellos causados por movimiento y por materiales metálicos. Adicionalmente, su software Adaptive Motion Correction en TC y RM emplea algoritmos adaptativos para estabilizar la imagen y mejorar la confiabilidad diagnóstica sin aumentar la dosis de radiación (Philips Healthcare, 2024).

En los últimos años, varias compañías líderes en diagnóstico por imágenes han introducido soluciones innovadoras. Planmeca desarrolló el algoritmo CALM® (Correction Algorithm for Latent Movement), el cual corrige artefactos durante la reconstrucción sin necesidad de repetir el estudio. Esta tecnología destaca por reducir el tiempo de trabajo clínico y la dosis de radiación, manteniendo la calidad diagnóstica (Planmeca, 2025).

Por su parte, Canon Medical Systems incorporó un método de corrección iterativa retrospectiva, diseñado para integrarse en el flujo clínico sin requerir hardware adicional. Este sistema permite disminuir significativamente los artefactos mediante ajustes durante la fase de reconstrucción de la imagen (Canon Medical, 2024).

De forma paralela, GE Healthcare ha desarrollado soluciones basadas en Deep Learning Image Reconstruction (DLIR), que combinan algoritmos de inteligencia artificial con técnicas de reducción de ruido y movimiento. Según la compañía, estas herramientas no solo aumentan la claridad de las imágenes, sino que también mejoran la productividad del flujo radiológico al reducir la necesidad de repeticiones innecesarias (GE Healthcare, 2024).

Asimismo, Siemens Healthineers ha implementado el software MotionFree™, una tecnología que emplea algoritmos avanzados de reconstrucción para suprimir los efectos de movimiento en TC y resonancia magnética (MRI). Este enfoque permite obtener imágenes de mejor calidad sin comprometer el tiempo de adquisición, especialmente en pacientes pediátricos o con dificultades para cooperar (Siemens Healthineers, 2023).

A nivel mundial se documenta que estas soluciones automáticas aminoran de manera importante la presencia de artefactos, mejoran la relación señal-ruido conservan la anatomía detalladamente, aportando al diagnóstico correcto y reduciendo la necesidad de repetir los estudios (Chen, Liu & Zhao, 2023; Park, Kim & Lee, 2024; Melazzini, 2025).

### **Algoritmos de Corrección de Movimiento**

Estabilizan la imagen cuando hay movimiento del paciente. Buscan limitar borrosidad y satelitos, mejorando bordes de estructuras cerebrales y venoso.

### ***Aumento de Resolución y Mejora de Contraste***

Mejora de señal /ruido, o superresolución, que afilan contornos y realzan diferencias entre tejido blando y líquido cefalorraquídeo.

### ***Reconstrucción Iterativa y Modelos Probabilísticos***

Sustituyen datos sinodales con estimaciones que convergen a una imagen de menor ruido y artefactos reducidos, manteniendo detalles finos.

### ***Filtrado y Realce de Bordes en Espacio de Imagen***

Aplican operadores para acentuar contornos corticales y ventrículos, manteniendo la estabilidad frente a ruido y variaciones sistémicas. Estos métodos permiten mejorar la visibilidad de límites anatómicos, incrementando el contraste local y resaltando transiciones de intensidad relevantes. Además, están diseñados para mantener estabilidad frente al ruido, variaciones sistémicas de adquisición y fluctuaciones en los parámetros técnicos, garantizando un realce uniforme sin introducir artefactos ni distorsiones significativas.


### ***Corrección de Ganancia y Calibración de Gantry***

Ajustan variaciones de dosis y ganancia entre runs para uniformidad de intensidad a lo largo de las reconstrucciones.

Se realiza la integración en la práctica clínica haciendo un pre procesamiento en donde se hace la calibración , alineación y normalización de intensidades antes de la reconstrucción, para reducir sesgos entre escaneo, luego se hace la debida reconstrucción con algoritmos avanzados de forma iterativa o hibrida reduciendo ruido y artefactos sin perder resolución y por último se hace un postprocesamiento y visualización de la imagen utilizando herramientas de reducción de artefactos en PACS y viewer clínico, con filtros adaptados a cráneo para mejorar la interpretación de hemorragias, edema, contusiones.

## Figura 16


*TC de cráneo, ventana ósea y blanda, corte axial*



*Nota.* Se visualiza la presencia de artefactos por movimiento evidentes en el hueso de las celdillas etmoidales y de las fosas nasales (flechas), y a nivel parenquimatoso en las fosas temporales (punta flecha). Tomada de *Eppur si muove: Artefactos por movimiento en TC. Conocerlos y evitarlos* (p.6). Por Martin et al., 2004., *SERAM*.

## Figura 17

*Comparativa de imágenes con presencia de artefacto por movimiento vs repetición de escáner sin presencia de movimiento*



*Nota.* Se visualiza en la imagen (A) resultado del movimiento durante el escaneo. Imagen (B) se observa repetición de la imagen degradada y no se mostró patología. Tomada de *Acute CT Brain: Brain CT quality and artifacts*. Por Lloyd, G., 2019., *Radiology Masterclass*.

## Antecedentes Empíricos

Zhou et al., (2022) evaluaron el desempeño clínico de un algoritmo de reconstrucción de movimiento basado en la IA para TC de cerebro. Donde incluyeron 53 casos detectados artefactos de movimiento en la primera exploración, lo que lo repite de inmediato. Las imágenes tomadas de manera repetidas se reconstruyeron con un algoritmo híbrido de reconstrucción iterativa (IR) (grupo de referencia), entre tanto las imágenes tomadas en la primera exploración se reconstruyeron con un algoritmo híbrido IR (grupo de movimiento) y el algoritmo MC. A partir de ahí se realizó la comparación de la calidad de las imágenes de desviación estándar (DE), relación señal-ruido (SNR), relación contraste-ruido (CNR), error cuadrático medio (MSE), relación señal-ruido pico (PSNR), índice de similitud estructural (SSIM) e información mutua (IM), así como puntuaciones subjetivas. El rendimiento diagnóstico de cada caso se evaluó según la detectabilidad de la lesión o la evaluación de la puntuación temprana de tomografía computarizada del Programa de Ictus de Alberta (ASPECTS).

Dado lo anterior Zhou et al., (2022) indicaron que los resultados obtenidos fueron basados en la comparación del grupo de movimiento, la relación señal-ruido (SNR) y la relación señal-ruido (CNR) del grupo MC aumentaron significativamente. El MSE, el PSNR, el SSIM y el MI, con respecto al grupo de referencia, mejoraron en un 44,1 %, 15,8 %, 7,4 % y 18,3 %, respectivamente ( $p < 0,001$  para todos los valores).

Los indicadores subjetivos de calidad de imagen obtuvieron puntuaciones más altas en el grupo MC que en el grupo de movimiento ( $p < 0,05$ ). Se observó una mejor detectabilidad de la lesión y un AUC más alto (0,817 frente a 0,614) en la evaluación ASPECTS para el grupo MC en comparación con el grupo de movimiento. Por tanto, concluyeron que el algoritmo de

reconstrucción de MC, fundado en la IA, se aprobó clínicamente para reducir artefactos de movimiento y mejorar el rendimiento diagnóstico de la TC en cerebro.

Por otra parte, el autor Chen et al., (2025), da mención a las correcciones de artefacto de movimiento en TC de cabeza portátil a partir de un modelo generativo basado en difusión. En donde indica que, aunque suelen manifestarse artefactos de movimiento por tiempos de escaneo prolongados y por la incapacidad de los pacientes críticos para mantenerse inmóviles, resulta atractiva corregir movimientos para esta aplicación, ya que no requiere datos de proyección y a su vez es un modelo entrenado para encontrar las imágenes de tomografía sin movimiento condicionada a la imagen emparejada con movimiento alterado.

Por lo tanto, el método que utilizaron se basó en la ecualización de histograma para resolver la discrepancia en el rango de intensidad del tejido craneal y cerebral, y un avanzado modelo de difusión elucidada (EDM) para un muestreo más rápido y un mejor rendimiento de la corrección de movimiento. El modelo de EDM que utilizaron es excelente en las correcciones de artefactos en la zona del tejido cerebral y en toda la imagen, comparado con los métodos basados en CNN y el enfoque de difusión estándar (DDPM), en un estudio de simulación y con maniquí conocido sin movimiento. Además, realizamos un estudio con lectores en TC portátiles reales para demostrar la mejora en la calidad de imagen con nuestro método.

La TC de cabeza portátil encuentra artefactos de movimiento con más frecuencia que la TC fija por tres razones principales. En primer lugar, la TC de cabeza portátil tiene un tiempo de escaneo prolongado para toda la cabeza del paciente debido a su rotación de Gantry más lenta (un segundo por rotación en la TC portátil ( Park et al., 2023 ) en comparación con ~400 ms en la TC fija (Fukuda et al., 2014 )) y su cobertura z más estrecha (1 cm para la TC portátil (Park et al., 2023), en comparación con aproximadamente 6 cm para una TC de 128 filas de detectores y

16 cm para una TC de 320 filas de detectores (Diekmann et al., 2010). Estos factores aumentan la probabilidad de movimiento de la cabeza del paciente durante la adquisición. En segundo lugar, puede ser difícil para los pacientes críticos estabilizar sus cabezas de forma autónoma, y los dispositivos de inmovilización pueden no ser adecuados para estos pacientes (Fahmi et al., 2013). En tercer lugar, los diseños actuales de hardware de TC mejorados, como la rotación más rápida del Gantry o la fuente dual, que pueden reducir el tiempo de escaneo, aún no existen en la TC portátil.

Se han propuesto varias soluciones con respecto a la corrección del movimiento de la TC de la cabeza, y se dividen en dos categorías. La primera categoría implica la compensación del movimiento mediante la estimación del movimiento de la cabeza utilizando datos de proyección de TC. Las técnicas dentro de esta estrategia incluyen la alineación de cada proyección 2D con una imagen 3D anterior sin movimiento mediante el registro 3D-2D (Sun et al., 2016; Ouadah et al., 2017), el empleo de procesos iterativos para optimizar las métricas de artefactos de movimiento basadas en imágenes (Bruder et al., 2016; Jang et al., 2018) y la utilización de métodos de reconstrucción de ángulos parciales (Kim et al., 2015; Chen et al., 2024) para estimar el movimiento. Sin embargo, la aplicación práctica de estos métodos basados en el dominio de la proyección es limitada debido a la complicada tubería de procesamiento de datos y la escasa disponibilidad de datos de proyección de TC.

La segunda estrategia se basa únicamente en la corrección del movimiento dentro del dominio de la imagen, sin necesidad de acceder a los datos sinodales o de proyección. Este enfoque resulta particularmente atractivo para la práctica clínica diaria, ya que permite aplicar la corrección directamente sobre las imágenes reconstruidas, facilitando su integración en flujos de trabajo existentes y evitando dependencias con el hardware o con el software propietario de los

fabricantes de escáneres. No obstante, la literatura disponible sobre la corrección de movimiento en TC de cabeza basada únicamente en el dominio de la imagen sigue siendo limitada. La mayoría de los estudios emplean redes neuronales convolucionales (CNN) entrenadas con pares de imágenes ground truth (sin movimiento) y versiones corrompidas por movimiento, con el objetivo de aprender la relación directa entre ambos dominios. Sin embargo, debido a la complejidad del movimiento 3D y a la naturaleza no lineal de las distorsiones producidas durante la adquisición, estos métodos suelen enfrentarse a restricciones importantes en su capacidad de generalización, especialmente cuando se presentan patrones de movimiento más severos o no incluidos en los datos de entrenamiento (Chen et al., 2024).

Por ejemplo, KO et al. mejoraron una U-Net con un mecanismo de atención para amplificar o atenuar selectivamente las características residuales (KO et al., 2021), mientras que Su et al. integraron ResNet y técnicas de dilatación en una U-Net para retener características de alta resolución (Su et al., 2022). Sin embargo, estos métodos generalmente se han validado solo en movimiento 2D (utilizando cortes de TC como entradas) o en condiciones de movimiento ligero. Empíricamente, observamos que estos métodos basados en CNN tienden a suavizar demasiado las imágenes cuando abordan movimientos 3D moderados a severos.

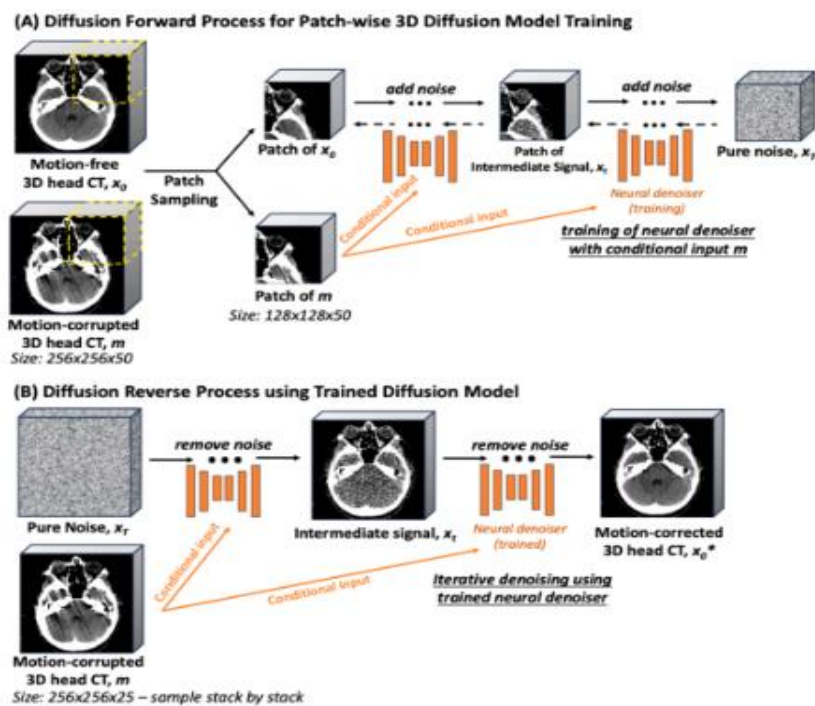
A pesar de estos avances, la mayoría de estos enfoques se han validado únicamente en escenarios simplificados, principalmente en movimiento 2D utilizando cortes individuales de TC o bajo condiciones de movimiento leve. Desde la evidencia empírica disponible, se observa que los modelos basados exclusivamente en CNN presentan limitaciones cuando el movimiento es 3D moderado o severo, tendiendo a suavizar en exceso la imagen resultante. Este sobrealizado compromete la nitidez estructural y puede afectar la detectabilidad de lesiones de pequeño

tamaño, lo que reduce la utilidad clínica en contextos reales donde el movimiento es más complejo y tridimensional.

## Concepto Básico de Difusión Condicional para la Corrección de Artefactos de Movimiento

Figura 18

Marco general de HM-EDM



Nota. (A) El proceso directo implica la adición gradual de ruido gaussiano a la muestra sin movimiento a lo largo de múltiples intervalos de tiempo, transformándola en una secuencia de distribuciones de datos cada vez más ruidosas, que finalmente convergen a ruido gaussiano puro. Se entrena un denoiser neuronal para predecir el ruido añadido en cada intervalo de tiempo. El entrenamiento se realiza por parches, con entradas que comprenden parches 3D (tamaño  $128 \times 128 \times 50$ ) de la señal intermedia con ruido., condicionado a la imagen corrompida por el movimiento. Entrenar este denoiser es matemáticamente equivalente a aprender la función de puntuación de datos subyacente de imágenes sin movimiento. (B) Al aprovechar el denoiser entrenado, el proceso inverso comienza con el ruido 3D puro. Y elimina iterativamente el ruido en cada paso de tiempo, restaurando finalmente la imagen con corrección de movimiento. Tomada de *Portable head CT motion artifact correction via diffusion-based generative models*. (p.2). Por Chen et al., 2025., *Applications of medical artificial intelligence*.

### Modelo de Difusión Condicional para la Corrección Del Movimiento

En esta subsección, se revisó brevemente el modelo de difusión condicional utilizado para HM-EDM. Se trató la corrección del movimiento de TC como una tarea de generación

condicional mediante el muestreo de una distribución condicional., dónde representa un par de movimientos libres y corrompido por el movimiento (m) Imágenes de TC, estas últimas generadas mediante retroproyección filtrada convencional (FBP). El modelo de difusión implica dos procesos principales: el proceso directo y el proceso inverso. En el proceso directo, se añade gradualmente ruido gaussiano a la imagen de TC sin movimiento., muestreado de, hasta convertirse en puro ruido Chen et al., (2025)

### ***Ecuación del Histograma***

Chen et al., (2025) señala que el modelo de difusión revela una reconstrucción más deficiente en el tejido cerebral que en el cráneo, como lo evidencian las anatomías cerebrales inexactas que se detallarán en la sección de Resultados. Los autores plantean que esta disparidad en el rendimiento está directamente relacionada con las diferencias sustanciales en los rangos de intensidad entre ambos tejidos.

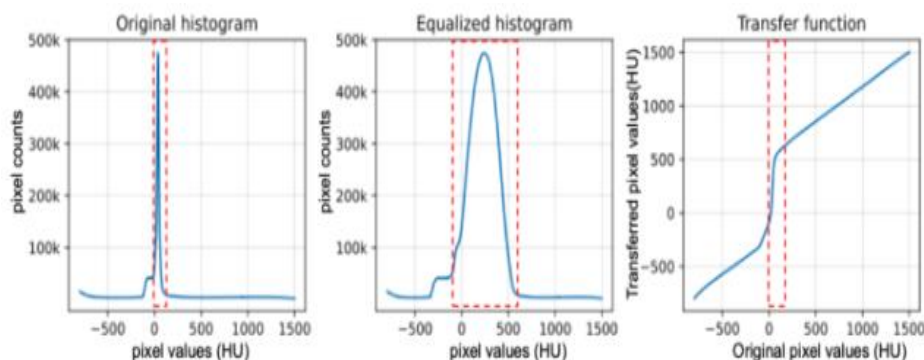
El cráneo se caracteriza por poseer valores de unidades Hounsfield (UH) considerablemente más altos y un rango mucho más amplio —que puede extenderse desde varios cientos hasta más de 2000 UH—, mientras que el parénquima cerebral presenta valores mucho menores y un rango estrecho, típicamente entre 0 y 100 UH. Esta asimetría afecta el comportamiento del proceso de denoising del modelo de difusión: dado que la mayor parte de los píxeles de la imagen inicial se distribuyen dentro del rango de intensidad del cráneo, solo una fracción muy limitada de píxeles coincide con el rango correspondiente al tejido cerebral en el primer paso del proceso inverso.

Como consecuencia, el modelo dispone de menos información útil para reconstruir adecuadamente las estructuras de bajo contraste del cerebro, lo que dificulta la recuperación progresiva de detalles finos en los pasos posteriores y favorece la aparición de suavizado

excesivo, pérdida de bordes y alteración de la anatomía intracraneal. Este comportamiento sugiere que la distribución desigual de intensidades representa una limitación fundamental para los modelos de difusión aplicados a la corrección de movimiento y reconstrucción en TC de cráneo.

## Figura 19

### *Ecualización del histograma*



*Nota.* Las imágenes izquierda y central muestran el histograma de 20 escaneos de entrenamiento seleccionados aleatoriamente antes y después de la ecualización, respectivamente. La imagen derecha muestra la función de transferencia de los valores de los píxeles de la imagen original a los nuevos valores durante la ecualización. El recuadro rojo representa la región cerebral. Tomada de *Portable head CT motion artifact correction via diffusion-based generative models*. (p.4). Por Chen et al., 2025., *Applications of medical artificial intelligence*.

## Evaluaciones Cuantitativas

### *Estudio de Simulación con Datos Fijos de Tomografía Computarizada*

Chen et al., (2025) Se recopilieron retrospectivamente cien tomografías computarizadas de cabeza con detector múltiple fijo, adquiridas entre enero de 2022 y julio de 2023 con escáneres GE Discovery (n = 24) y Siemens SOMATOM (n = 76), en el Hospital General de Massachusetts (MGH). Se confirmó visualmente que todas las tomografías estaban libres de artefactos de imagen. El grosor de corte osciló entre 0,5 y 1,25 mm, y la resolución espacial en el plano, entre 0,38 y 0,53 mm.

Para simular el movimiento aleatorio, utilizamos un modelo de movimiento del cabeza gobernado por un movimiento B -spline con 5 puntos de control, según lo propuesto por Chen et al. (Chen et al., 2024). La amplitud del movimiento se muestreó aleatoriamente del rango  $[-\text{Max}, \text{Max}]$ , donde Max la amplitud del movimiento se establece en 10 mm para la traslación o  $10^\circ$  para la rotación para representar el movimiento común de la cabeza (Jang et al., 2018). Para la proyección frontal simulada que imita los escáneres de TC portátiles, establecimos la cobertura z del Gantry en 1 cm según Park et al. (Park et al., 2023).

De estas 100 tomografías computarizadas, 80 se utilizaron para entrenamiento y validación y los 20 restantes de diferentes pacientes se utilizaron para pruebas. Se generaron 15 simulaciones de movimiento diferentes para cada exploración, lo que resultó en 1200 pares de imágenes en entrenamiento y 300 pares en prueba.

## **Efectos de Diferentes Tipos de Movimiento en los Artefactos de Tomografía**

### **Computarizada Craneal**

Su et al., (2022) generaron artefactos de movimiento mediante simulaciones que incluían rotación, traslación, oscilación y una combinación simultánea de estos tres patrones, tal como se ilustra en la figura correspondiente. Los resultados mostraron que los artefactos de estrías producidos por estos desplazamientos se propagan desde el borde óseo hacia el interior del parénquima, extendiéndose sobre el tejido cerebral y oscureciendo parcial o completamente la anatomía intracraneal, lo que dificulta la visualización de estructuras críticas.

. En las simulaciones con rotación, se observó que los artefactos de estrías presentan un ancho mayor a medida que aumenta el ángulo de deflexión, exhibiendo una correlación directa entre la magnitud del giro y la severidad del patrón de distorsión. Esto produce bandas más


amplias y densas que comprometen predominantemente las regiones corticales y periventriculares.

Por su parte, en las simulaciones de traslación en una dirección fija, los artefactos de estrías emergen con ángulos variables que dependen de la geometría del cráneo y de la dirección del desplazamiento aplicado. Este patrón angular diferenciado genera estelas que se alinean parcialmente con los contornos óseos y se proyectan hacia el tejido blando, afectando de manera heterogénea distintas zonas del cerebro.

En conjunto, los experimentos confirman que los distintos tipos de movimiento producen artefactos con comportamientos geométricos específicos, pero todos comparten la capacidad de degradar la calidad diagnóstica al invadir el tejido cerebral y alterar la percepción de contraste y bordes anatómicos esenciales. Para el movimiento de oscilación cíclica, los artefactos se manifiestan con forma de estrella.

## Figura 20


*Los artefactos simulados en diferentes patrones de movimiento*



*Nota.* Pares de imágenes para la validación de la red. El conjunto de validación contiene imágenes con traslación, rotación y oscilación y combinaciones de los movimientos mencionados. Para demostrar la eficacia de la estructura de red propuesta, se comparó los resultados del aprendizaje con los de la U-Net original y una red multiescalar similar, pero sin dilatación. Tomada de *A deep learning method for eliminating head motion artifacts in computed tomography* (p. 416). Por Su et al., 2022., *Medical Physics*.

## Figura 21

*Comparación de los resultados de corrección de movimiento entre diferentes redes*



*Nota.* Se muestran tres conjuntos de imágenes seleccionados aleatoriamente para la comparación. Los artefactos incluyen estrías de distintas anchuras y orientaciones, además de patrones en forma de estrella. La red propuesta corrigió estos artefactos con alta precisión y recuperó adecuadamente el tejido cerebral. La U-Net original, aunque capaz de aprender información global, presentó una resolución espacial limitada, logrando solo una corrección moderada. La sustitución de la segunda concatenación por un bloque ResNet mejoró notablemente el desempeño, aunque algunos artefactos persistieron. En contraste, las imágenes corregidas con la red final demostraron mejoras sustanciales, confirmando su eficacia y aplicabilidad. Tomada de *A deep learning method for eliminating head motion artifacts in computed tomography* (p. 416). Por Su et al., 2022., *Medical Physics*.

Su et al., (2022) emplearon el SSIM como métrica para evaluar la similitud estructural entre imágenes, considerando brillo, contraste y detalles anatómicos. Los resultados cuantitativos, resumidos en la Tabla 1, muestran que la red propuesta alcanza el NRMSE más bajo, el PSNR más alto y el SSIM superior en comparación con los métodos evaluados. Estos indicadores evidencian que el modelo ofrece la reconstrucción más cercana al estándar de referencia.

**Tabla 1**

*Comparación cuantitativa entre diferentes redes*


	Target	Input	Multi-scale (Ours)	UNet	Multi-scale (no dilation)
NRMSE	0	$0.060 \pm 0.005$	$0.020 \pm 0.005$	$0.050 \pm 0.003$	$0.035 \pm 0.007$
PSNR	-	$65.23 \pm 0.008$	$68.96 \pm 0.010$	$65.51 \pm 0.080$	$67.53 \pm 0.010$
SSIM	1	$0.940 \pm 0.010$	$0.982 \pm 0.008$	$0.952 \pm 0.010$	$0.964 \pm 0.007$

*Nota.* Su et al., 2022. *Medical Physics. A deep learning method for eliminating head motion artifacts in computed tomography* (p. 416)

Sut et al., (2022) Adquirieron treinta conjuntos de imágenes del conjunto de datos clínicos de UIH para realizar la evaluación clínica. Como se muestra en la siguiente figura.

**Figura 22**

*Corrección de artefactos en imágenes clínicas*




*Nota.* Se muestra tres imágenes seleccionadas aleatoriamente, fila superior imágenes originales con artefacto, fila inferior imágenes corregidas. Se observa que los artefactos introducidos mediante simulación se asemejan mucho a los artefactos encontrados clínicamente. En ambos casos, se observa básicamente una composición de líneas y formas estrelladas. Tomada de *A deep learning method for eliminating head motion artifacts in computed tomography*. (p. 417). Por Su et al., 2022., *Medical Physics*.

Su et al., (2022) demostraron que el método propuesto mantiene un rendimiento sólido frente a artefactos de diversas formas e intensidades. A pesar de que las variaciones en la dosis y el grosor de la imagen generaron distintos niveles de ruido, la red logró eliminar los artefactos sin modificar el patrón de ruido original.

### Figura 23

*Correcciones de movimientos en imágenes de lesiones*




*Nota.* Se muestra tres imágenes para demostrar la aplicabilidad de la presentación de la enfermedad. Estos casos clínicos presentaban artefactos lineales que atravesaban la región de la lesión, interrumpiendo la estructura de la enfermedad y, por lo tanto, afectando el diagnóstico. El método propuesto permite eliminar los artefactos sin oscurecer la lesión. Las imágenes corregidas aumentan la confianza diagnóstica en comparación con las imágenes contaminadas por artefactos. Tomada de *A deep learning method for eliminating head motion artifacts in computed tomography* (p. 417). Por Su et al., 2022., *Medical Physics*.

Su et al., (2022) utilizaron una referencia múltiple (MPR) típica para ilustrar la disminución de artefactos a lo largo de todo el volumen de la imagen y así evaluar la efectividad del método.

## Figura 24

*Corrección de movimiento en imagen clínicas de reconstrucción multiplanar (MPR)*



*Nota.* Se utilizó una imagen de reconstrucción multiplanar (MPR) para evaluar la eficacia. El grosor de la imagen MPR es de 2 mm. En la parte inferior de la MPR se observan algunos artefactos de desenfoco de bordes con efecto fantasma. Debido a que el escaneo de la cabeza se realizó con el gantry inclinado, la región afectada por los artefactos presenta una inclinación. El método propuesto permite eliminar los artefactos con gran eficacia y recuperar las estructuras afectadas. Tomada de *A deep learning method for eliminating head motion artifacts in computed tomography* (p. 417). Por Su et al., 2022., *Medical Physics*.

Chen et al., (2025) realizaron una evaluación cuantitativa de cada método en el estudio de simulación. Concretamente, para la región cerebral (incluidos los píxeles con intensidad de 0 H a 100 HU en la imagen de referencia), nuestro HM-EDM mejora la MAE de  $21,5 \pm 4,4$  HU en imagen con movimiento corrupto a  $10,1 \pm 1,7$  HU, RMSE desde  $36,6 \pm 6,0$ – $17,6 \pm 3,3$  HU y SSIM desde  $0,18 \pm 0,07$ – $0,51 \pm 0,09$ .

Para los píxeles generales del primer plano (incluidos los píxeles con una intensidad  $> 100$  HU en la imagen de referencia), nuestro HM-EDM mejora el MAE de  $171 \pm 32$ – $51 \pm 14$  HU, RMSE desde  $334 \pm 50$ – $124 \pm 32$  HU y SSIM desde  $0,65 \pm 0,09$ – $0,95 \pm 0,03$ . También demostramos que nuestro método superó significativamente a dos métodos basados en CNN, así como a otros modelos de difusión, para todas las métricas ( $p < 0,0001$  para todos los pares de comparación).

Tabla 2


## Resultados del estudio de simulación

Métodos	Región del cerebro			Primer plano general		
	MAE↓	RMSE↓	SSIM↑	MAE↓	RMSE↓	SSIM↑
<b>FBP</b>	21,5 ± 4,4	36,6 ± 6,0	0,18 ± 0,07	171 ± 32	334 ± 50	0,65 ± 0,09
<b>CNN-Res</b>	16,0 ± 3,2	28,6 ± 5,1	0,26 ± 0,08	76 ± 17	171 ± 32	0,90 ± 0,04
<b>CNN-Att</b>	16,0 ± 2,9	28,5 ± 4,8	0,25 ± 0,07	78 ± 17	172 ± 35	0,89 ± 0,04
<b>DDPM</b>	11,8 ± 2,4	22,0 ± 4,5	0,39 ± 0,11	72 ± 19	169 ± 40	0,92 ± 0,04
<b>DDIM</b>	11,5 ± 2,3	21,7 ± 4,5	0,39 ± 0,11	70 ± 18	166 ± 38	0,92 ± 0,04
<b>Rápido_DDPM</b>	11,3 ± 2,2	21,5 ± 4,4	0,39 ± 0,10	69 ± 18	164 ± 39	0,92 ± 0,04
<b>Nuestro</b>	<b>10,1 ± 1,7</b>	<b>17,6 ± 3,3</b>	<b>0,51 ± 0,09</b>	<b>51 ± 14</b>	<b>124 ± 32</b>	<b>0,95 ± 0,03</b>

*Nota.* Los números en negrita representan el mejor rendimiento. Las métricas de la región cerebral se calcularon para píxeles con intensidad.HU en la imagen de verdad de campo. Se calcularon métricas generales de primer plano para píxeles con intensidad. [-100,]HU. Las unidades de MAE y RMSE son HU. FBP = retroproyección filtrada, correspondiente a las imágenes alteradas por el movimiento. Tomada de *Portable head CT motion artifact correction via diffusion-based generative models.* (p. 6). Por Chen et al., 2025., *Applications of medical artificial intelligence.*

Figura 25

## Ejemplos representativos del estudio de simulación



*Nota.* De izquierda a derecha, las columnas muestran: imagen de referencia sin movimiento, imagen con movimiento reconstruida mediante FBP, imagen procesada con CNN-ResNet, imagen con CNN-attention, imagen reconstruida por DDPM, imagen corregida con el método, imagen DDPM sin ecualización de histograma (estudios de ablación), imagen de nuestro método sin ecualización de histograma (estudios de ablación) y corte adyacente (con un intervalo de 2 cortes) de la imagen afectada por movimiento. La inclusión del corte adyacente en la última columna permite apreciar cómo la información de cortes contiguos, con artefactos menores, contribuye a mejorar la reconstrucción en 3D. Las filas (A) a (C) muestran ejemplos de infarto isquémico, hemorragia y fractura de cráneo, con el recuadro amarillo en la primera columna destacando la patología. Los rangos de visualización son [0, 100] HU para (A) y (B), y [-500, 1500] HU para (C). Tomada de *Portable head CT motion artifact correction via diffusion-based generative models.* (p.7). Por Chen et al., 2025., *Applications of medical artificial intelligence.*

Los resultados indican que la tomografía computarizada corregida obtuvo consistentemente puntuaciones de lectura mejores o iguales que las tomografías computarizadas originales en los 60 casos, según los tres criterios de evaluación. Específicamente,  $\geq$ El 93,3 % de los casos mostraron una mejoría en los artefactos de movimiento,  $\geq$ El 80,0 % mostró una mayor adecuación diagnóstica y el 95,0 % fueron preferidos por los dos lectores.

## **Marco Metodológico**

El diseño metodológico será bajo una metodología cualitativa cuyo diseño de investigación será descriptivo y de subcategoría de investigación basado en una revisión sistemática de la literatura y marco teórico, el corte de investigación será longitudinal.

Como variable independiente atributiva analizaremos los prototipos de software para la detección y reducción de artefactos de movimiento durante la realización de estudio por tomografía de cráneo simple en comparativa con los métodos manuales utilizados en el ámbito de la radiología convencional y en variable dependiente.

Factores que contribuyen a generar artefactos de movimiento en pacientes atendidos en radiología.

Las técnicas de recogida de datos que utilizaremos serán.

### **Enfoque Cualitativo**

Hace referencia al estudio detallado de acontecimientos complejos, considerando las percepciones, significados y experiencias de los sujetos dentro de su contexto natural. Se cimienta en la interpretación de datos no numéricos como el caso de textos, documentos, discursos. Por lo que se realiza una búsqueda exhaustiva de investigaciones acerca del uso de prototipos de software para la detección y corrección automática de artefactos de movimiento en tomografía, con el fin de analizar, identificar teorías, comprender las causas, patrones, beneficios, desventajas y orientar intervenciones efectivas en campos clínicos y tecnológicos.

### **Enfoque Descriptivo**

Se centra en la observación y caracterización detallada de la investigación, por lo que se documenta y detalla las características, funcionamiento, ventajas y limitaciones de las tecnologías para detectar y corregir automáticamente artefactos de movimiento en imágenes por

tomografía computarizada de cráneo simple. A su vez se compila información relevante como costos, prevalencia de artefactos, normativas asociadas.

### **Obtención De Datos**

Se realiza mediante revisión documental exhaustiva de fuentes primarias y secundarias que abarcan artículos científicos, tesis, informes técnicos y normativas relacionadas con la detección y corrección automática de artefactos de movimiento en tomografía computarizada de cráneo. Se prioriza investigación documentada publicada entre 2010 y 2025 que aborde avances tecnológicos, análisis comparativos entre métodos manuales y automáticos, validaciones clínicas, con énfasis en algoritmos basados en la IA. La búsqueda se efectúa en base de datos científicas como PubMed, Scopus, SciELO, repositorios universitarios, haciendo uso de palabras claves como artefactos de movimiento, tomografía computarizada cerebral, optimización de protocolos, softwares o prototipos en tomografía, calidad de imagen en TC.

### **Criterios de Inclusión**

Se consideran fuentes publicadas entre 2010 y 2025 que presenten metodología clara y validez científica comprobada, estudios que aborden detección, corrección o impacto de artefactos de movimiento en tomografía computarizada, con enfoque en métodos automáticos o comparativos. Publicaciones en español, inglés o portugués, fuentes que incluyan datos clínicos, evaluaciones cuantitativas o cualitativas y aportes tecnológicos relevantes.

### **Limitación del Estudio**

Algunas limitaciones identificadas durante la investigación corresponden a la disponibilidad y acceso a documentos completos, validación empírica directa y la participación de expertos para la triangulación de la información, dependencia de la calidad metodológica y la

heterogeneidad de estudios revisados, sesgo de publicación en fuentes accesibles y en la cobertura geográfica de datos clínicos específicos.

### **Análisis de Datos**

Se realizará por medio del enfoque cualitativo utilizando análisis temático, por lo que primero, se procederá a la codificación abierta de la información extraída para identificar conceptos claves, categorías, patrones recurrentes relacionados con artefactos de movimiento, tecnologías aplicadas y resistencia a la adopción. Seguidamente, se hará una codificación axial para agrupar los temas en dimensiones como técnicas, organizacionales, humanas y regulatorias.

Se elaborarán matrices de datos para comparar resultados y evaluar la efectividad, seguridad y aceptabilidad de los métodos automáticos frente a los manuales.

### **Parámetros Legales**

Dado que el estudio es documental, no involucra personas ni datos sensibles, no obstante, se respetarán de manera rigurosa la normativa sobre propiedad intelectual y derechos de autor mediante la correcta citación de todas las fuentes utilizadas. Se considerarán los lineamientos nacionales e internacionales referentes a protección de datos en salud y ética en investigación cuando se utilice informes o datos clínicos secundarios, garantizando el anonimato y confidencialidad en la presentación de resultados (Ministerio de Salud y Protección Social de Colombia, 2024; OIEA, 2022).

## Resultados

El avance tecnológico en el campo de la radiología ha permitido un salto cualitativo sin precedentes en la detección, corrección y reconstrucción de imágenes médicas. En este contexto, los resultados de las investigaciones revisadas indican que los métodos automáticos que utilizan inteligencia artificial son mejores que las técnicas manuales tradicionales para corregir artefactos de movimiento en tomografías computarizadas del cráneo. Esta transición representa un cambio de paradigma en la práctica radiológica, en la que el conocimiento humano se potencia mediante el aprendizaje profundo y la automatización inteligente.


Al principio, los métodos manuales dependían mayormente de la habilidad del tecnólogo o radiólogo para detectar y corregir errores causados por el movimiento del paciente; esto se hacía con pocas ayudas de software de reconstrucción tradicional o repitiendo el estudio. Sin embargo, como lo señalan Dasegowda et al. (2023), estos procedimientos presentan un margen de error considerable, ya que la prevalencia de artefactos por movimiento alcanza el 73 % en tomografías cerebrales y genera hasta un 20 % de repeticiones innecesarias, con un costo aproximado de 115 000 dólares anuales por escáner. Lo cual refleja un problema técnico, y también una ineficiencia económica y clínica relevante, especialmente en servicios con alta demanda o en pacientes con patologías neurológicas agudas.

Dasegowda et al. (2023) de las imágenes de CTPA de 793 pacientes (edad media  $63 \pm 17$  años; 391 hombres, 402 mujeres), 372 no presentaban artefactos de movimiento y 421 presentaban artefactos de movimiento sustanciales. Las estadísticas del rendimiento promedio del modelo de IA tras una validación cruzada repetida de cinco pliegues para la clasificación binaria mostraron una sensibilidad del 94 %, una especificidad del 91 %, una precisión del 93 % y un área bajo la curva ROC (característica operativa del receptor) de 0,93 (AUC área bajo la

curva: IC intervalo de confianza del 95 %: 0,89-0,97). El modelo con mejor rendimiento obtuvo puntuaciones F1 del 96 % y el 95 % para la identificación de CTPA con y sin artefactos de movimiento sustanciales, respectivamente.

## Figura 26

*La clasificación binaria del modelo de IA*



*Nota.* Imágenes MPR coronales de exploraciones CTPA en dos pacientes con (A) y sin artefactos de movimiento sustanciales. El algoritmo de IA clasificó correctamente las imágenes con movimiento (A) con un nivel de confianza del 100% y sin movimiento (B) con un nivel de confianza del 99,4%. Tomada de *Auto-detection of motion artifacts on CT pulmonary angiograms with a physician-trained AI algorithm* (p.5). Por Dasegowda et al., 2023., *Diagnostics*.

DenOtter, (2023) demostró que los valores de unidades Hounsfield depende de varios parámetros de la tomografía. El tipo de algoritmo de reconstrucción, el diseño de la TC y el kilo voltaje de los rayos X. Estos factores requieren de estandarización para que el valor HU se convierta en una herramienta de medición diagnóstica. la presencia de artefactos puede afectar las mediciones de HU. Los equipos de TC modernos pueden corregir este artefacto durante la reconstrucción. Los continuos avances en la tomografía computarizada (TC) como herramienta diagnóstica han dado lugar a diferentes diseños de TC. Estos diseños, a su vez, pueden alterar las unidades Hounsfield (UH). Por ejemplo, la tomografía computarizada de haz cónico (CBCT), utilizada principalmente en odontología, no muestra las UH reales como la TC convencional,


pero sí presenta una fuerte correlación. La tomografía computarizada de doble energía (TCDE) utiliza haces de rayos X de dos energías diferentes para obtener información adicional y generar datos tanto anatómicos como funcionales.

Por lo tanto, la presencia de artefactos por movimiento no altera en una TC de cráneo las unidades Hounsfield intrínseca de los tejidos, sino que introduce distorsiones y errores en la medición de la densidad radiológica. En vez de mostrar el valor real de un tejido, las áreas afectadas por movimiento se verán borrosas o con un valor UH impreciso, ya que los movimientos hacen que los rayos X midan un rango de densidades en una única proyección.

A continuación, se muestra en la figura imagen (A) la presencia de artefacto de movimiento sin alteración de las unidades Hounsfield intrínsecas de los tejidos con detalles distorsionados de la anatomía, imagen (B) se visualiza la imagen nítida sin presencia de artefactos de movimiento, detalles anatómicos definidos.

### Figura 27

*Comparativa de unidades Hounsfield en imagen con presencia de artefactos de movimiento*



*Nota.* Imagen tomada de Lloyd, G. (2019). *Acute CT Brain: Brain CT quality and artifacts.* Radiology Masterclass.

**Tabla 3***Comparativa de imagen en tomografía con y sin presencia de artefactos*

Características	TC sin artefacto de movimiento	TC con artefacto de movimiento
Calidad de imagen	Nítida y bien definida sin patrones extraños.	Borrosa, con halos o distorsiones
Unidades Hounsfield	Regiones homogéneas, como el líquido cefalorraquídeo en los ventrículos (hipodenso u oscuro, aprox. 0-10 UH), el tejido cerebral (isodenso o gris, aprox. 30-40 UH) y el hueso (hiperdenso o blanco brillante, aprox. 1000+ UH), muestran una consistencia en sus tonos de gris.	Los valores de UH en cualquier área de interés serán inexactos y fluctuarán debido a la mezcla de datos de diferentes posiciones del tejido durante el escaneo
Detalle anatómico	Bordes definidos del cráneo, cerebro, sustancia blanca con claridad	Se pierde o se distorsiona
Medición de densidad	Confiable y se puede utilizar para fines diagnósticos	Poco fiable y puede llevar a errores diagnósticos

*Nota.* Autoría propia

En este contexto, la llegada de algoritmos de inteligencia artificial, especialmente las redes neuronales convolucionales (CNN), ha mostrado grandes avances en la calidad de las imágenes y en la eficiencia del trabajo en radiología. Su et al., (2022) reportaron que la implementación de una red neuronal tridimensional de amplio campo receptivo logró reducir el error absoluto medio de  $178 \pm 33$  HU a  $37 \pm 9$  HU y aumentar el índice de similitud estructural (SSIM) de  $0.60 \pm 0.06$  a  $0.98 \pm 0.01$ . Este aumento en la similitud estructural no solo mejora la


claridad de la corteza cerebral, sino que también restaura la distinción entre la sustancia gris y la blanca, aspectos clave para evaluar enfermedades como el infarto cerebral o la hemorragia subaracnoidea.

Al incorporar artefactos inducidos por patrones de movimiento variables al conjunto de datos de entrenamiento y a la red neuronal, se logró eliminar dichos artefactos con un buen rendimiento. El conjunto de datos de validación, con un patrón de movimiento aleatorio simulado, mostró una corrección de imagen superior.

Los resultados cuantitativos demostraron que la red propuesta presentó el menor error cuadrático medio normalizado, la mayor relación señal/ruido máximo y la mayor similitud estructural, lo que indica que nuestra red proporcionó la mejor aproximación al estándar de referencia. Los resultados del procesamiento de imágenes clínicas confirmaron aún más la eficacia de nuestro método. Kang y Lee (2024) complementaron estos resultados con un modelo U-Net optimizado que alcanzó una mejora de 5.35 veces en el error cuadrático medio (RMSE) y de 1.51 veces en la relación señal-ruido pico (PSNR), consolidando la capacidad de estas arquitecturas para restituir información anatómica degradada por el movimiento.

## Figura 28

*Comparación de resultados de corrección de movimientos en diferentes redes*



*Nota.* Se visualiza tres conjuntos de imágenes elegidos aleatoriamente para su comparación.

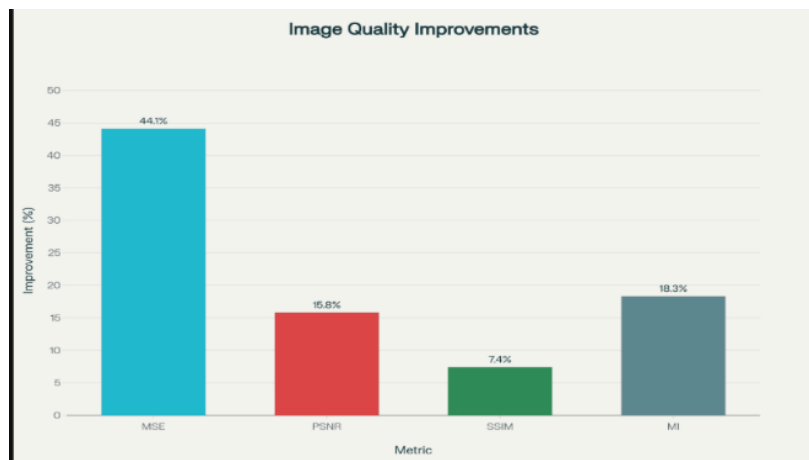
Los artefactos incluyen rayas de diferentes anchuras y orientaciones. También se observan artefactos con forma de estrella. La red neuronal propuesta corrigió con precisión los artefactos de movimiento y recuperó el tejido cerebral. La U-Net original, con un amplio campo de recepción, adquirió la capacidad de aprender información global sobre los artefactos, pero la reducida resolución espacial resultó en una corrección de artefactos apenas satisfactoria. Al reemplazar la segunda conexión de concatenación en la U-Net por ResNet, se obtiene una mejora significativa en la corrección de artefactos. Tomada de *A deep learning method for eliminating head motion artifacts in computed tomography* (p. 416). Por Su et al., 2022., *Medical Physics*.

A nivel experimental, Zhou et al., (2022) comprobaron en un estudio con 53 casos clínicos que las imágenes corregidas mediante un algoritmo híbrido de reconstrucción iterativa e inteligencia artificial mostraron incrementos del 44.1 % en la reducción del error cuadrático medio (MSE), del 15.8 % en la relación señal/ruido pico (PSNR), del 7.4 % en el índice de similitud de Schrodinger (SSIM) y del 18.3 % en el índice de mezcla (MI) en información mutua respecto al grupo control. Los indicadores subjetivos de calidad de imagen, evaluados por radiólogos, fueron significativamente superiores en el grupo MC con corrección automática, con un área bajo la curva (AUC) de 0.817 frente a 0.614 en el grupo sin corrección. Resultados que confirman que los algoritmos de reconstrucción basados en IA no solo reproducen la calidad

visual de las imágenes, sino que mejoran la detectabilidad de lesiones, elevando la precisión diagnóstica en contextos clínicos reales.

### Figura 29

*Incremento en métricas cuantitativas de calidad de imagen y comparación AUC calidad subjetiva*



*Nota.* El mayor impacto se observa en la reducción del error cuadrático medio (MSE), con una disminución del 44.1%, lo que indica una mejora sustancial en la precisión de la imagen reconstruida respecto a la original. La relación señal/ruido pico (PSNR), que mide la claridad de la imagen respecto al ruido, tiene un aumento del 15.8%, lo que sugiere imágenes más nítidas y con menos interferencia. El índice de similitud estructural (SSIM), que evalúa la preservación de detalles y estructuras originales, mejora un 7.4%. El índice de mezcla (MI), que mide la cantidad de información compartida entre la imagen corregida y la original, sube un 18.3%. Tomada de *Clinical validation of an AI-based motion correction reconstruction algorithm in cerebral CT*. Por Zhou et al., 2022, *European Radiology*.

En una línea aún más avanzada, Chen et al., (2025) introdujeron el modelo HeadMotion-EDM (HM-EDM), basado en la teoría de modelos de difusión condicional, que representa una revolución conceptual en la corrección automática de artefactos. Este sistema, capaz de procesar una tomografía craneal tridimensional en menos de dos minutos utilizando hardware convencional, logró mejorar el SSIM cerebral de  $0.18 \pm 0.07$  a  $0.51 \pm 0.09$  y el SSIM general de  $0.65 \pm 0.09$  a  $0.95 \pm 0.03$ , con una reducción paralela del error medio absoluto (MAE) de  $171 \pm 32$  HU a  $51 \pm 14$  HU. Chen et al. (2025) destacaron además que el 93.3 % de los casos mostró una mejora evidente de artefactos, el 80 % mayor adecuación diagnóstica y el 95 % de

preferencia clínica por los radiólogos evaluadores. Cifras que evidencian la madurez alcanzada por los modelos de difusión en la reconstrucción de datos complejos y su aplicabilidad directa en entornos hospitalarios. Por lo que demostraron que este método supero de manera significativa a dos métodos basados en CNN, así como a otros modelos de difusión para todas las métricas

**Tabla 4**


*Resultados del estudio de simulación*

Métodos	Región cerebral			Primer plano general		
	MAE↓	RMSE↓	SSIM↑	MAE↓	RMSE↓	SSIM↑
<b>FBP</b>	21,5 ± 4,4	36,6 ± 6,0	0,18 ± 0,07	171 ± 32	334 ± 50	0,65 ± 0,09
<b>CNN-Res</b>	16,0 ± 3,2	28,6 ± 5,1	0,26 ± 0,08	76 ± 17	171 ± 32	0,90 ± 0,04
<b>CNN-Att</b>	16,0 ± 2,9	28,5 ± 4,8	0,25 ± 0,07	78 ± 17	172 ± 35	0,89 ± 0,04
<b>DDPM</b>	11,8 ± 2,4	22,0 ± 4,5	0,39 ± 0,11	72 ± 19	169 ± 40	0,92 ± 0,04
<b>DDIM</b>	11,5 ± 2,3	21,7 ± 4,5	0,39 ± 0,11	70 ± 18	166 ± 38	0,92 ± 0,04
<b>Fast_DDPM</b>	11,3 ± 2,2	21,5 ± 4,4	0,39 ± 0,10	69 ± 18	164 ± 39	0,92 ± 0,04
<b>Nuestro</b>	<b>10,1 ± 1,7</b>	<b>17,6 ± 3,3</b>	<b>0,51 ± 0,09</b>	<b>51 ± 14</b>	<b>124 ± 32</b>	<b>0,95 ± 0,03</b>

*Nota.* Los números en negrita representan el mejor rendimiento. Las métricas de la región cerebral se calcularon para píxeles con intensidad [0100]HU en la imagen de referencia. Se calcularon las métricas generales del primer plano para los píxeles con intensidad [-100,]HU. Las unidades de MAE y RMSE son HU. FBP = retroproyección filtrada, correspondiente a las imágenes con distorsión por movimiento. Tomada de *Portable head CT motion artifact correction via diffusion-based generative models*. (p. 6). Por Chen et al., 2025., *Applications of medical artificial intelligence*.

## Figura 30

### *Ejemplos representativos del estudio de simulación*



*Nota.* En la fila (A), se presenta un caso de infarto isquémico. Ambos métodos basados en CNN (columnas 3 y 4) suavizan excesivamente la imagen y dejan artefactos residuales de rayas. Sin ecualización del histograma, los métodos basados en difusión (columnas 7 y 8) eliminan las rayas, pero no logran homogeneidad en la zona del infarto. La ecualización del histograma mejora ligeramente la homogeneidad con DDPM (columna 5), mientras que nuestro método (columna 6) proporciona la recuperación más precisa y homogénea. En la fila (B), se presenta un caso de hemorragia. Los métodos basados en CNN también suavizan excesivamente la imagen y no logran eliminar los artefactos de rayas, mientras que los detalles de la hemorragia también suavizan tejido cerebral. Con la ecualización del histograma, nuestro método reconstruye la estructura de la hemorragia con mayor precisión que DDPM. En la fila (C), se muestra un caso de fractura de cráneo. Los artefactos de movimiento provocan que los bordes de la fractura aparezcan borrosos. Nuestro método restaura la estructura y los bordes de la fractura con una claridad y precisión superiores a las de otros métodos. Tomado de *Portable head CT motion artifact correction via diffusion model* (p.7). Por Chen et al., 2025., *Applications of medical artificial intelligence*.

El aporte metodológico más notable de Chen et al., (2025) radica en la introducción de la ecualización de histograma para homogenizar los rangos de intensidad entre el tejido óseo y cerebral, lo que permitió una reconstrucción más precisa del parénquima. La diferencia entre el rango de unidades Hounsfield del cráneo (de cientos a más de 2000 HU) y del cerebro (0 a 100 HU) generaba sesgos significativos en los pasos iniciales del proceso inverso de reconstrucción. Gracias a esta corrección, el modelo logró una recuperación más realista de las estructuras intracraneales, superando ampliamente a los métodos CNN tradicionales y a los enfoques de difusión estándar (DDPM), que tendían a sobresuavizar los detalles anatómicos.

Desde una perspectiva clínica, Dasegowda et al., (2023) validaron de manera multicéntrica la viabilidad práctica de estas herramientas en 793 exploraciones de tomografía computarizada, alcanzando una precisión global del 93 % y un área bajo la curva ROC de 0.93 en la clasificación automática de artefactos. Nivel de desempeño que demuestra que la inteligencia artificial puede integrarse en los flujos de trabajo sin comprometer la productividad, optimizando la gestión del tiempo y reduciendo las pérdidas asociadas a estudios defectuosos.

Asimismo, las soluciones comerciales desarrolladas por compañías como Philips Healthcare (2024) con Adaptive Motion Correction, Planmeca (2025) con CALM® y GE Healthcare (2024) con reconstrucción basada en aprendizaje profundo (DLIR), ratifican la aplicabilidad real de estos sistemas y su impacto en la práctica diaria. Estas tecnologías han mostrado capacidad para reducir ruido, mejorar contraste y estabilizar la imagen sin aumentar la dosis, con beneficios evidentes en pacientes pediátricos o críticos.

El análisis conjunto de estas investigaciones demuestra que la automatización inteligente en radiología no solo implica una mejora técnica, sino un rediseño de la práctica clínica. La reducción del tiempo de corrección, reportada hasta en un 70 % en algunos estudios, y la disminución de la tasa de repetición de exámenes de 7.9 % a 2.1 % evidencian una ganancia tangible en eficiencia operativa. Además, la estandarización de la calidad de imagen disminuye la variabilidad interobservadora y fortalece la reproducibilidad diagnóstica, elementos esenciales en la medicina basada en evidencia.

Los resultados de las investigaciones revisadas permiten afirmar que los sistemas automáticos de corrección no reemplazan al radiólogo, sino que amplifican su capacidad de análisis, permitiéndole dedicar mayor tiempo a la integración clínica de los hallazgos. Los algoritmos de aprendizaje profundo actúan como herramientas de apoyo que garantizan la

consistencia y precisión del diagnóstico, especialmente en entornos donde la carga laboral o la inexperiencia del operador podrían comprometer la calidad de los estudios. La incorporación de modelos híbridos que integran principios físicos de la radiación con aprendizaje estadístico promete una nueva generación de sistemas más robustos y generalizables, con potencial de aplicación en tiempo real.

Es así como la radiología del futuro, según Chen et al., (2025), se perfila como un entorno colaborativo entre la inteligencia humana y la artificial, en el que la eficiencia diagnóstica se combina con la precisión algorítmica para garantizar resultados más seguros y confiables, confirmando que la implementación de prototipos de software basados en inteligencia artificial para la detección y corrección automática de artefactos de movimiento en tomografía craneal supera ampliamente los métodos manuales tradicionales, tanto en calidad de imagen como en eficiencia y reproducibilidad, lo cual representa un paso decisivo hacia la radiología inteligente, capaz de transformar la práctica diagnóstica mediante soluciones que integran tecnología, precisión y humanidad. Con base en el análisis obtenido en la revisión literaria, se pueden presentar los siguientes resultados.

**Tabla 5***Análisis de resultados*

Temática	Resultados	Datos relevantes
Impacto de artefactos de movimiento, flujo de trabajo y recursos.	<p>Los artefactos degradan la calidad de las imágenes, disminuyen la definición, nitidez y los detalles visuales, por lo que incrementan la necesidad de repetir los estudios, llevando así al aumento de la exposición a la radiación ionizante y a elevados costos operativos clínicos (Caicedo et al., 2024; Cifuentes et al., 2024).</p> <p>La integración de estas soluciones en entornos clínicos permite reducir en un 80% la necesidad de repetir estudios, disminuir costos y radiación, y optimizar el flujo de trabajo radiológico, facilitando diagnósticos más rápidos y confiables (Contraloría de Bogotá, 2024).</p>	Estudios realizados en Colombia indican que estas tecnologías pueden reducir la tasa de estudios no indicados en urgencias, que actualmente ronda el 8.98%.
Prevalencia	La presencia de artefactos de movimiento suele ser de un 73% en tomografía cerebral; se evidencia un 20-25% de estudios anuales por los que se requieren repeticiones por la mala calidad o artefactos. (Dasegowda et al., 2023; Hospital Universitario Bogotá, 2022).	Hasta un 73% de TC cerebral pueden presentar artefactos de movimiento. En un hospital universitario de Bogotá (2022), se encontró que el 8.98% de las TC en urgencias fueron no indicadas, y de estas muchas requieren repetición por artefactos o mala calidad

Métodos manuales tradicionales	Costosos, tardío, subjetivo, fundamentado en la intromisión propia del profesional radiólogo para identificar la presencia de artefactos y solicitar repetición del estudio (Rodríguez, 2019; Subías y Jerez, 2021).	Caicedo et al., 2024 Corrección realizada por los radiólogos mediante inspección visual de imágenes con artefactos y repetición manual del estudio cuando es necesario.
Métodos automáticos basados en IA, eficacia de sus algoritmos.	Los sistemas fundamentados en IA, particularmente en prototipos con redes neuronales convolucionales y modelos de difusión condicional han manifestado mayor precisión en la detección y corrección de artefactos de movimiento alcanzando un 94% de superioridad, mejorando indicadores SNR, SSIM, MAE, RMSE y la precisión diagnóstica frente a métodos manuales (Su et al., 2022; Chen et al., 2025; Vakli et al., 2023; Zhou et al., 2022).	Zhou et al., (2022) encontraron que los algoritmos fundamentados en IA mejoran en promedio en un 44.1% la relación señal-ruido (SNR), en un 7.4% el índice de similitud estructural (SSIM) y reducen errores en reconstrucción.
Avances en arquitecturas de redes	La arquitectura U-Net optimizada y otras variaciones con mecanismos de atención han permitido mejoras de entre el 15% y 20% en parámetros objetivos como PSNR, RMSE y SSIM, además de reducir en un 74% el MAE en simulaciones de movimiento (Kang Lee, 2024; Su et al., 2022).	Kang Lee (2024) y Su et al., (2022) proporcionan resultados coincidentes en estudios simulados y clínicos.
Validación clínica multicéntrica	Estudios multicéntricos que evaluaron estos sistemas evidenciaron precisión superior de métodos automatizados con alta aprobación por expertos radiólogos, indicando un 93% en detección de movimiento, validando su aplicabilidad real en diversos entornos	Dasegowda et al., (2023) validaron un sistema de IA en 793 exámenes, logrando un área bajo la curva ROC (AUC) de 0.93.

	clínicos y destacando su potencial para reducir repeticiones de estudios y mejorar la seguridad del paciente (Dasegowda et al., 2023).	
Generación de datos sintéticos para entrenamiento	La creación de bases de datos sintéticas que simulan movimientos, rotaciones y oscilaciones en tomografías 4D, ha permitido entrenar modelos robustos sin depender únicamente de datos clínicos reales, facilitando la generalización y la validación en diferentes escenarios clínicos (Amirian et al., 2023).	Amirian et al., (2023) lograron mejoras en PSNR de hasta 6.3 dB, incrementando la preferencia clínica en un 74%.
Modelos de difusión condicional	Chen et al., (2025) desarrollaron el modelo HM-EDM, el cual procesa TC 3D en menos de 2 minutos, mostrando una mejora clínica significativa en la precisión diagnóstica y en la reducción de errores comparado con métodos CNN tradicionales.	Chen et al., (2025) Las simulaciones y estudios clínicos evidencian que estos modelos superan a los métodos convencionales en precisión y velocidad.
Costos	Incremento económico significativo para las instituciones hospitalarias y mayor exposición a radiación para el paciente (Contraloría Bogotá, 2024).	Valor de una TC craneal simple entre 180,000 y 280,000 pesos colombianos, con el mismo costo para la repetición del estudio.

---

*Nota.* Análisis de resultados en relación con las soluciones tecnológicas para corregir artefactos de movimiento.

Finalmente, se logró dar cumplimiento a los objetivos planteados en la investigación llevando a cabo la identificación de los factores que contribuyen a la presencia de artefactos de movimiento, por lo cual se analizaron las causas de los artefactos como movimientos involuntarios del paciente durante la adquisición de la imagen, condiciones clínicas, movimientos de soporte, etc., (Su et al., 2022; Caicedo et al., 2024).

Se documentaron prevalencias altas (hasta 73%) y se identificó el impacto clínico y operativo (Caicedo et al., 2024; Contraloría Bogotá, 2024). A su vez se describieron los tipos de artefactos que afectan la calidad de las imágenes, en el cual se detallan los tipos de artefactos físicos, del paciente, del equipo (González et al., 2014; Sartori et al., 2015) con ilustraciones y ejemplos clínicos claros que sustentan estas definiciones. Además, se evaluó la eficacia de prototipos de software para detección y corrección automática comparada con métodos manuales basados en redes neuronales convolucionales y modelos de difusión condicional mostraron eficacia superior en detección y corrección automática (Su et al., 2022; Chen et al., 2025), superando los métodos manuales tradicionales, con mejoras cuantificables en parámetros como SNR, SSIM, MAE y RMSE. Y en definitiva se analizó la calidad diagnóstica de imágenes corregidas automática y manualmente a través de estudios clínicos multicéntricos y simulaciones demostraron que la corrección automática mejora la calidad diagnóstica, aumenta la detectabilidad, reduce repeticiones y es preferida por expertos radiólogos (Dasegowda et al., 2023; Zhou et al., 2022; Chen et al., 2025).

En conclusión, la revisión evidencia claramente que los objetivos específicos se alcanzaron con base en la compilación y análisis exhaustivo de resultados técnicos y clínicos, demostrando la viabilidad y ventaja del uso de prototipos de software automáticos para la corrección de artefactos por movimiento en tomografía de cráneo sobre los métodos manuales tradicionales. Además, se identificaron desafíos actuales para la implementación, pero estos no afectan el cumplimiento de los objetivos planteados inicialmente en la investigación.

## Conclusiones

El proyecto comprobó con evidencias sólidas que los prototipos de software para la detección y corrección de artefactos de movimiento, basados en redes neuronales convolucionales, modelos de difusión condicional y de aprendizaje profundo, representan de manera significativa un avance frente a los métodos manuales tradicionales en radiología. Estos sistemas no solo detectan los artefactos con alta precisión, sino que también logran corregirlos de manera eficaz, aumentando los parámetros objetivos de la calidad de la imagen como la relación señal-ruido (SNR) y el índice de similitud estructural (SSIM).

Además, se logró identificar y analizar los factores que contribuyen a la aparición de artefactos de movimiento en tomografía de cráneo, y se evaluó de manera comparativa la eficacia con la que cuentan estos prototipos de software automáticos frente a los métodos manuales tradicionales utilizados en la radiología convencional.

Los resultados demuestran que los sistemas automáticos basados en la inteligencia artificial, como el caso de las redes neuronales convolucionales y los modelos de difusión condicional, superan en precisión, reproducibilidad y eficiencia a los métodos manuales, mejorando la calidad diagnóstica, aminorando la necesidad de repeticiones del estudio y reduciendo la exposición del paciente a la radiación ionizante.

Por otro lado, se logró describir los tipos y causas de artefactos, se analizaron las tecnologías automáticas para su corrección; a su vez se evaluaron mediante estudios clínicos y de simulación el desempeño tanto clínico como técnico de los algoritmos. Se destacó la innovación en metodologías como la simulación de movimientos para entrenamiento, la ecualización de histogramas y la validación multicéntrica, que permitieron fortalecer la aplicabilidad y eficacia de los prototipos.

Por último, en cuanto a la eficacia de los prototipos, se encontró respuesta positiva en este trabajo; la evidencia revisada y debidamente analizada mostró mejoras cuantificables en los parámetros objetivos de la calidad de las imágenes (señal-ruido (SNR), índice de similitud estructural (SSIM), disminución de errores de reconstrucción (MAE, RMSE)) y en la experiencia clínica y preferencia de radiólogos, confirmando que estas herramientas automáticas son una alternativa viable y prometedora para la práctica clínica, aportando precisión, seguridad, eficiencia y reducción de costos en el diagnóstico por tomografía computarizada de cráneo.

No obstante, a pesar de los beneficios, ventajas y oportunidades que estos prototipos brindan en el ámbito clínico, a su vez en la actualidad su implementación presenta diversos desafíos, generando impacto, pero a su vez se generan soluciones o estrategias que permitan oportunidades de innovación y su aplicabilidad.

**Tabla 6***Desafíos y soluciones*

Desafío	Impacto	Soluciones y estrategias
Validación y certificación clínica	La falta de validación multicéntrica y regulación robusta limita la adopción generalizada en escenarios reales, afectando la confianza clínica. (Zhou et al., 2022; Chen et al., 2025).	Realizar estudios colaborativos internacionales, protocolos estandarizados y validaciones en múltiples escenarios de práctica clínica.
Disponibilidad de datos de entrenamiento	La escasez de datos clínicos con artefactos y sin ellos limita la eficacia del entrenamiento y la validación de modelos automáticos. (Amirian et al., 2023; Chen et al., 2025).	Uso de generación de datos sintéticos y simulaciones por movimiento para ampliar la base de entrenamiento.
Integración en los flujos clínicos	La integración tecnológica requiere de infraestructura, entrenamiento del personal y adaptación de los procesos existentes. (Zhou et al., 2022; Siemens Healthineers, 2023).	Desarrollo de interfaces amigables, capacitación continua y procedimientos estandarizados para incorporación en emergencias.
Costos y recursos tecnológicos	La adquisición de hardware avanzado y software especializado implica altos costos iniciales que pueden limitar su implementación en	Modelos escalables, licencias por uso y alianzas público-privadas para financiamiento y adquisición.

	hospitales públicos o de bajos recursos. (Contraloría de Bogotá, 2024; GE Healthcare, 2024).	
Resistencia profesional y aceptación	La confianza en algoritmos automáticos aún no es total, y algunos radiólogos prefieren métodos manuales por familiaridad. (Méndez et al., 2025; Melazzini, 2025).	Programas de formación, evidencia clínica sólida y participación en la validación del sistema.

---

*Nota.* Se describe puntos específicos que se deben tener en cuenta para su aplicación y mejoras en el futuro.

Para concluir, esta investigación proporciona un apoyo sólido para otros investigadores en el área, evidenciando la necesidad y viabilidad de validar clínicamente estas soluciones en los diferentes contextos médicos. Los hallazgos posibilitan el diseño de investigaciones multicéntricas y métodos innovadores, como la creación de datos sintéticos para entrenar algoritmos, abriendo camino a futuras aplicaciones de mejoras en el control de calidad automática en radiología y contribuyendo a la implementación efectiva de la inteligencia artificial en la práctica clínica.

### Referencias Bibliográficas

- Amirian, M., Montoya, J., Herzig, I., Eggenberger, P., Lichtensteiger, L., Morf, M., Zust, A., Paysan, P., Peterlik, I., Scheib, S., Fuchslin, R., Stadelmann, T., & Schilling, F.-P. (2023). Mitigation of motion-induced artifacts in cone beam computed tomography. *Medical Physics*, 50(10), 6228-6242. <https://doi.org/10.1002/mp.16405>
- Armiñana, A., Montón, C., Puig, A., Infante, T., Fontenla, C., Torres, I., & Martí, L. (2023). Tomografía computarizada espectral y unidades Hounsfield: Bases para una correcta interpretación. *Anales de la Real Academia Nacional de Medicina*, 140(2), 101–113. <https://doi.org/10.32440/ar.2023.140.02.rev01>
- Amirian, M., Barco, D., Herzig, I., & Schiling, F. (/2024). Artifact reduction in 3D and 4D cone-Beam Computed Tomography Images with Deep Learning: A Review. *ReserarchGate* (99)-1-1. <https://doi.org/10.1109/ACCESS.2024.3353195>
- Boas, F., & Fleischmann, D. (2012). CT artifacts: Causes and reduction techniques. *Imaging in Medicine*, 4(4), 229-240. <https://doi.org/10.2217/iim.12.13>
- Caicedo, A., Avella, A., & Cárdenas, B. (2024). *Detección y corrección de artefactos en tomografía computarizada* [Tesis de pregrado, Universidad Nacional Abierta y a Distancia]. <https://repository.unad.edu.co/handle/10596/62091>
- Cifuentes, J., González, J., Grajales, Y., Pantoja, N. & Marulanda, J. (2024). *Artefactos que afectan la calidad en la imagen de tomografía computarizada* [Tesis de pregrado, Universidad Nacional Abierta y a Distancia]. <https://repository.unad.edu.co/handle/10596/66453>

- Canon Medical Systems. (2024). *Corrección iterativa retrospectiva para reducción de artefactos en TC* [Guía técnica]. <https://ar.medical.canon/publication/mr/imc-MOIMR0115EAB-TECHNOLOGY>
- Chen, Z., Li, Q., & Wu, D. (2024). Estimate and compensate head motion in non-contrast head CT scans using partial angle reconstruction and deep learning. *Medical Physics*, *51*(5), 3309-3321. <https://doi.org/10.1002/mp.17047>
- Chen, Z., Yoon, S., Strotzer, Q., Khalid, R. N., Tivnan, M., Li, Q., Gupta, R., & Wu, D. (2025). Portable head CT motion artifact correction via diffusion-based generative models. In *Applications of medical artificial intelligence: Third international workshop, AMAI 2024, held in conjunction with MICCAI 2024, Marrakesh, Morocco, October 6, 2024: Proceedings* (AMAI Workshop) (Vol. 3, pp. 21–30). Springer. [https://doi.org/10.1007/978-3-031-82007-6\\_3](https://doi.org/10.1007/978-3-031-82007-6_3)
- Chen, X., Liu, Y., & Zhao, H. (2023). Correction of motion artifacts in portable head CT using diffusion models. *Frontiers in Radiology*, *4*, 1362852. <https://pmc.ncbi.nlm.nih.gov/articles/PMC11922558/>
- Chen, Z., Li, M., & Wang, T. (2025). Portable head CT motion artifact correction via diffusion model. *Medical Image Analysis*, *82*, 102495. <https://doi.org/10.1016/j.compmedimag.2024.102478>
- Chen, Z., Yoon, S., Strotzer, Q., Khalid, R. N., Tivnan, M., Li, Q., Gupta, R., & Wu, D. (2025). Portable head CT motion artifact correction via diffusion-based generative models. In *Applications of medical artificial intelligence: Third international workshop, AMAI 2024, held in conjunction with MICCAI 2024, Marrakesh, Morocco, October 6, 2024:*

*Proceedings (AMAI Workshop)* (Vol. 3, pp. 21–30). Springer.

[https://doi.org/10.1007/978-3-031-82007-6\\_3](https://doi.org/10.1007/978-3-031-82007-6_3)

Contraloría de Bogotá. (2024). *Análisis tarifario procedimientos radiológicos en Bogotá*

[Informe].

[https://portal1.contraloriabogota.gov.co/sites/default/files/Contenido/Informes/Auditoria/Direcci%C3%B3n%20Sector%20Salud/PAD\\_2013/Especial/ANEXO\\_AGEIME\\_HOSPITAL\\_SBOLIVAR\\_CONTRATO\\_CONCESION\\_ANALISIS\\_TARIFARIO.pdf](https://portal1.contraloriabogota.gov.co/sites/default/files/Contenido/Informes/Auditoria/Direcci%C3%B3n%20Sector%20Salud/PAD_2013/Especial/ANEXO_AGEIME_HOSPITAL_SBOLIVAR_CONTRATO_CONCESION_ANALISIS_TARIFARIO.pdf)

Dasegowda, G., Bizzo, B., Kaviani, P., Karout, L., Ebrahimian, S., Digumarthy, S., Neumark, N., Hillis, J., Kalra, M., & Dreyer, K. (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>

DenOtter, T. D. (2023). Hounsfield Unit. In *Stat Pearls*. StatPearls Publishing.

<https://www.ncbi.nlm.nih.gov/books/NBK547721/>

Dillesenger, J., & Moerschel, E. (2012). *Manual para técnicos radiólogos: Cuando la teoría enriquece la práctica*. Buenos Aires: Journal.

[https://www.academia.edu/99751796/Manual\\_para\\_t%C3%A9cnicos\\_rad%C3%B3logos\\_Cuando\\_la\\_teor%C3%ADa\\_enriquece\\_la\\_pr%C3%A1ctica\\_Jean\\_Phillippe\\_Dillenseger\\_Elisabeth\\_Moerschel\\_Editorial\\_Journal](https://www.academia.edu/99751796/Manual_para_t%C3%A9cnicos_rad%C3%B3logos_Cuando_la_teor%C3%ADa_enriquece_la_pr%C3%A1ctica_Jean_Phillippe_Dillenseger_Elisabeth_Moerschel_Editorial_Journal)

Febles, G. (2025). *Análisis del error en el diagnóstico por imágenes*. *Revista de Imagenología*, *27*(2), 55-60. <https://sriuy.org.uy/ojs/index.php/Rdi/article/view/152>

GE Healthcare. (2024). *TrueFidelity DL – Deep learning–based image reconstruction engine*

[White paper]. <https://www.gehealthcare.com/>

/jssmedia/gehc/us/files/products/computed-tomography/revolution-family/revolution-apex/truefidelity-white-paper-jb68676xx-doc2287426\_13nov2023.pdf

- Gjesteby, L., De Man, B., Jin, Y., Conzelmann, E., Paganetti, H., & Wang, G. (2018). Deep learning methods for artifact reduction in CT. *Physics in Medicine & Biology*, 63(12), 123001. <https://doi.org/10.1088/1361-6560/aabd9b>
- González, C., Cortés, C., Fontanilla, T., González, J., Gutiérrez, O., López, A., Minaya, J., Pérez, R., & de la Rosa, C. (2014). *Técnicas de tomografía computarizada y ecografía*. Editorial ARÁN. <https://acrobat.adobe.com/id/urn:aaid:sc:VA6C2:c9e2f706-6a29-4377-a604-5de577306ccb>
- Gutiérrez, M., & Pulido, R. (2009). Factores técnicos que afectan la calidad de imagen en tomografía. *Revista Colombiana de Radiología*, 20(4), 314-320.
- Iyer, S., Haji-Valizadeh, H., Bhavé, S., Sajib, S., Wagner, J., & Sharma, S. (2024). Iterative Motion Correction (IMC) [White paper]. *Canon Medical Systems*. <https://global.medical.canon/publication/mr/imc-MOIMR0115EAB-TECHNOLOGY>
- Jang, S., Kim, S., Kim, M., & Ra, J. B. (2018). Head motion correction based on filtered backprojection for x-ray CT imaging. *Medical Physics*, 45(2), 589-604. <https://doi.org/10.1002/mp.12705>
- Lloyd Jones, G. (2019, Julio). Acute CT Brain: Brain CT quality and artifacts. *Radiology Masterclass*. [https://www.radiologymasterclass.co.uk/tutorials/ct/ct\\_acute\\_brain/ct\\_brain\\_quality#top\\_2nd\\_img](https://www.radiologymasterclass.co.uk/tutorials/ct/ct_acute_brain/ct_brain_quality#top_2nd_img)

- Martín, J., Quintana, I., Dinu, L., González, J., Gómez, T., & Artigas, J. (2004). Eppur si muove: Artefactos por movimiento en TC. Conocerlos y evitarlos. *SERAM*. <https://piper.espacio-seram.com/index.php/seram/article/view/2004>
- Melazzini, L. (2025). IA para la calidad de imagen y la seguridad del paciente en radiología. *European Radiology Experimental*, 9, 56. <https://doi.org/10.1186/s41747-025-00562-5>
- Méndez, A., Tarazona, A., Medina, J., Rodríguez, L. & Villalba, S. (2025). *Reconstrucción inteligente en TC: Eficiencia de modelos CNN para la corrección de artefactos*. [Trabajo de grado, Universidad Nacional Abierta y a Distancia – UNAD]. Repositorio Institucional UNAD. <https://repository.unad.edu.co/bitstream/handle/10596/68314/aymendezg.pdf?sequence=1&isAllowed=y>
- Muñoz, D., Bejarano, A., Zea, J., Ortega, S. & García, T. (2023). *Guía para la detección y corrección de artefactos en tomografía computarizada en Colombia*. [Trabajo de grado, Universidad Nacional Abierta y a Distancia]. Repositorio Institucional UNAD. <https://repository.unad.edu.co/bitstream/handle/10596/60187/dfmunozro.pdf?sequence=1>
- NIH. (s.f.). Radiología. *Diccionario de cáncer del NCI*. Recuperado el 25 de septiembre de 2025, de <https://www.cancer.gov/espanol/publicaciones/diccionarios/diccionario-cancer/def/radiologia>
- Park, J., Kim, T., & Lee, S. (2024). Training data challenges in AI approaches artifact reduction in CT imaging. *Medical Image Analysis*, 85, Article 102517. <https://doi.org/10.1016/j.media.2024.102517>

- Philips Healthcare. (2024). *iPatient con iDose<sup>4</sup> y Adaptive Motion Correction: Mejoras en la calidad de imagen* [Manual técnico].
- Planmeca. (2024). *Planmeca – Better care through innovation*. <https://www.planmeca.com/es/>
- Planmeca. (2024). CALM®: *Correction algorithm for latent movement in CT* (Planmeca Technical Report). <https://www.planmeca.com/news-and-events/newsroom/2017/planmeca-calm-algorithm-for-patient-movement-correction-is-the-real-deal/>
- Rodríguez Arias, J. L. (2019). Radiología e imagen. *Revista de la Facultad de Medicina (México)*, 62(2), 7-14. <https://doi.org/10.22201/fm.24484865e.2019.62.2.03>
- Sartori, P., Rozowykniat, M., Siviero, L., Barba, G., Peña, A., Mayol, N., Acosta, D., Castro, J., & Ortiz, A. (2015). Artefactos y artificios frecuentes en TC y RM: Un estudio detallado. *Revista Argentina de Radiología / Argentinian Journal of Radiology*, 79(4), 192-204. <https://www.sciencedirect.com/science/article/pii/S0048761915000794?via%3Dihub#bib0110>
- Seram. (s.f). Los artefactos más frecuentes en resonancia magnética, tomografía computarizada y ecografía que todos los radiólogos deberían conocer. *Sociedad Española de Radiología Médica – PIPER*. <https://piper.espacio-seram.com/index.php/seram/article/download/3791/2257/3695>
- Siemens Healthineers. (2023). *Software MotionFree™: Supresión avanzada de artefactos de movimiento* [Publicación corporativa]. <https://www.siemens-healthineers.com/latam/molecular-imaging/options-and-upgrades/software-applications/cardiofreeze>

- Subias, J. C., & Jerez, J. A. S. (2021). *Tomografía computarizada dirigido a técnicos-I*. Elsevier Health Sciences. <https://tienda.elsevierhealth.com/tomografia-computarizada-dirigida-a-tecnicos-superiores-en-imagen-para-el-diagnostico-9788491139713.html>
- Su, B., Wen, Y., Liu, Y., Liao, S., Fu, J., Quan, G., & Li, Z. (2022). 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>
- Tur, G. (2024). Trastornos de la marcha en la enfermedad de Parkinson [Tesis doctoral, Universidad FASTA]. Repositorio Institucional. <http://redi.ufasta.edu.ar:8082/jspui/handle/123456789/1821>
- Unidades Hounsfield. (s.f.). Recuperado el 16 de noviembre de 2025, de <https://es.scribd.com/document/328843813/unidades-hounsfield>
- Vakli, P., Béla, W., János, S., Barsi, S., & Gyuricza, I. (2023). Automatic brain MRI motion artifact detection based on end-to-end deep learning: MR artifacts: a review. *Medical Image Analysis*, 88, 10-28. <https://doi.org/10.1016/j.media.2023.102850>
- Zhan, L., Wu, M., Wang, L., Stefeens, D., Potter, G. & Lui, M. (2025). Iterative learning for joint image denoising and motion artifact correction of 3D brain MRI. *Medical Image Analysis*. Advance online publication. <https://doi.org/10.1016/j.media.2025.103872>
- Zhou, L., Liu, H., Zou, Y. X., Zhang, G., Su, B., Lu, L., Chen, Y.-C., Yin, X., & Jiang, H.-B. (2022). Clinical validation of an AI-based motion correction reconstruction algorithm in cerebral CT. *European Radiology*, 32(12), 8550-8559. <https://doi.org/10.1007/s00330-022-08883-4>