



UNIVERSIDAD PERUANA
CAYETANO HEREDIA

Facultad de
MEDICINA

REDUCCIÓN DE ARTEFACTOS METÁLICOS EN TOMOGRAFÍA
COMPUTARIZADA: MÉTODOS CLÁSICOS E INTELIGENCIA ARTIFICIAL
OPEN SOURCE

METAL ARTIFACTS REDUCTION FOR COMPUTED TOMOGRAPHY
SCANS: CLASSICAL AND OPEN SOURCE ARTIFICIAL INTELLIGENCE
METHODS

TRABAJO ACADÉMICO PARA OPTAR POR EL TÍTULO DE SEGUNDA
ESPECIALIDAD PROFESIONAL EN TECNOLOGÍA EN TOMOGRAFÍA
COMPUTARIZADA

AUTORA

NATALY LUCIA MONTEBLANCO FERNANDEZ

ASESOR

EDWARD ARTEMIO MECA CASTRO

CO-ASESOR

CARLOS ANDRES HUAYANAY ESPINOZA

LIMA – PERÚ

2025

ASESORES DE TRABAJO ACADÉMICO

ASESOR

Mg. EDWARD ARTEMIO MECA CASTRO

Departamento Académico de Tecnología Médica

ORCID: 0000-0002-1226-9299

CO-ASESOR

Mg. CARLOS ANDRES HUAYANAY ESPINOZA

Departamento Académico de Tecnología Médica

ORCID: 0000-0002-8462-3218

Fecha de aprobación: 22 de abril de 2025

Calificación: Aprobado.

DEDICATORIA

A mis padres por ser los pilares que iluminan mi vida, por el infinito amor, la perseverancia, por estar siempre pendiente de mí, agradezco a Dios por bendecirme con padres maravillosos.

Mi eterna gratitud a mis hermanos, familiares, docentes que siempre estuvieron pendientes de los pasos que voy dando.

AGRADECIMIENTO

Al Mg. Carlos Andrés Huayanay Espinoza por el valioso apoyo incondicional, en
el asesoramiento de mi trabajo académico.

A la Universidad Peruana Cayetano Heredia por habernos acogido todos estos
meses que duro el desarrollo de nuestra segunda especialidad profesional.

FUENTES DE FINANCIAMIENTO

Este trabajo fue autofinanciado.

DECLARACIÓN DE CONFLICTO DE INTERÉS

La autora declara no tener conflictos de interés.

RESULTADO DEL INFORME DE SIMILITUD



UNIVERSIDAD PERUANA
CAYETANO HEREDIA

Facultad de
MEDICINA

REDUCCIÓN DE ARTEFACTOS METÁLICOS EN TOMOGRAFÍA
COMPUTARIZADA: MÉTODOS CLÁSICOS E INTELIGENCIA ARTIFICIAL
OPEN SOURCE

METAL ARTIFACTS REDUCTION FOR COMPUTED TOMOGRAPHY
SCANS: CLASSICAL AND OPEN SOURCE ARTIFICIAL INTELLIGENCE
METHODS

TRABAJO ACADÉMICO PARA OPTAR POR EL TÍTULO DE SEGUNDA
ESPECIALIDAD PROFESIONAL EN TECNOLOGÍA EN TOMOGRAFÍA
COMPUTARIZADA

AUTORA
NATALY LUCIA MONTEBLANCO FERNANDEZ

ASESOR
EDWARD ARTEMIO MECA CASTRO

CO-ASESOR
CARLOS ANDRES HUAYANAY ESPINOZA

LIMA - PERÚ
2025



8% Similitud estándar

Filtros

2 Exclusiones →

Fuentes

Mostrar las fuentes solapadas ⓘ

1 Internet ▾

repositorio.upch.edu.pe 3%

6 bloques de texto 129 palabra que coinciden

2 Internet ▾

hdl.handle.net 1%

9 bloques de texto 70 palabra que coinciden

3 Internet ▾

pesquisa.bvsalud.org <1%

3 bloques de texto 25 palabra que coinciden

4 Internet ▾

pubmed.ncbi.nlm.nih.gov <1%

1 bloques de bloques 20 palabra que coinciden

TABLA DE CONTENIDOS

| | Pág. |
|------------------------------------|-------------|
| RESUMEN | |
| ABSTRACT | |
| I. INTRODUCCIÓN | 1 |
| II. OBJETIVOS | 3 |
| III. CUERPO..... | 4 |
| IV. CONCLUSIONES | 14 |
| V. REFERENCIAS BIBLIOGRÁFICAS..... | 15 |
| ANEXOS | |

RESUMEN

Introducción: La presencia de artefactos metálicos en tomografía computarizada afectan la calidad de la imagen diagnóstica, lo que ha impulsado el desarrollo de métodos como la reconstrucción iterativa, el uso de inteligencia artificial (IA) y la tomografía computarizada de energía dual para su reducción. **Objetivo:** Describir cómo los métodos clásicos e inteligencia artificial open source mejoran la calidad de imagen y la interpretabilidad diagnóstica en tomografía computarizada al reducir los artefactos metálicos producidos. **Metodología:** Se realizó una revisión narrativa de artículos en inglés publicados en los años 2010 al 2025. Asimismo, se consideró referencias bibliográficas de expertos en el tema, sin consideración de los años, por la importancia relevante de la información. Los documentos fueron extraídos de Pubmed y Google Scholar. **Descripción de hallazgos:** Se encontraron 27 artículos donde se resalta que la principal diferencia entre ambos métodos (clásicos e IA) es el grado de reducción de los artefactos, sin embargo, al usar ambas técnicas se pudo observar mayor fiabilidad en el diagnóstico por imágenes. De la misma manera, se evidenció que, en el Perú, métodos como SEMAR y MARs mejoran la tomografía computarizada hasta en un 82% y 48% en la interpretabilidad diagnóstica, respectivamente. Asimismo, a nivel global, Quad-Net supera a DuDoNet y DANNet en precisión en la reconstrucción (RMSE 0.86, PSNR 43.45 dB, SSIM 98.16%). **Conclusiones:** Se evidencia que los métodos clásicos son efectivos en implantes pequeños, mientras que la IA mejora la reconstrucción de imágenes con mayor precisión y menos ruido. La combinación de ambos enfoques resulta ser la estrategia más eficaz.

Palabras claves: Reducción de Artefactos Metálicos, Tomografía, Rayos X Competitivos, Algoritmos, Inteligencia Artificial.

ABSTRACT

Introduction: The presence of metallic artifacts in computed tomography affects diagnostic image quality, driving the development of methods such as iterative reconstruction, artificial intelligence (AI), and dual-energy computed tomography for their reduction. **Objective:** To describe how classical methods and open-source artificial intelligence improve image quality and diagnostic interpretability in computed tomography by reducing metallic artifacts. **Methodology:** A narrative review was conducted on English-language articles published between 2010 and 2025. Additionally, bibliographic references from experts in the field were considered, regardless of publication year, due to the relevance of the information. The documents were sourced from PubMed and Google Scholar. **Description of findings:** Similarly, it was evidenced that, in Peru, methods such as SEMAR and MARs improve computed tomography by up to 82% and 48% in diagnostic interpretability, respectively. Likewise, at a global level, Quad-Net outperforms DuDoNet and DANNet in reconstruction accuracy (RMSE 0.86, PSNR 43.45 dB, SSIM 98.16%). **Conclusions:** Classical methods are effective for small implants, while AI enhances image reconstruction with greater precision and less noise. The combination of both approaches proves to be the most effective strategy.

Keywords: Metallic Artifact Reduction, Computed Tomography, Competitive X-Rays, Algorithms, Artificial Intelligence.

I. INTRODUCCIÓN

La presencia de artefactos metálicos en tomografía computarizada (TC) representa un problema significativo que afecta al 21% de las exploraciones, impactando negativamente en la calidad diagnóstica y la interpretación clínica (1). Estos artefactos generan distorsión en las imágenes, especialmente en las regiones cercanas a implantes dentales, prótesis de cadera, stents, clavos ortopédicos, entre otros dispositivos metálicos. Cabe señalar que los implantes dentales concentraron el 24% de las investigaciones relacionadas con la reducción de artefactos metálicos (2). Estas cifras evidencian el interés académico y clínico en el tema, sustentado por una creciente producción científica enfocada en desarrollar soluciones que mejoren la interpretabilidad (Anexo 18) y confiabilidad diagnóstica (3).

A lo largo de los años, se han propuesto y perfeccionado diversos métodos para la reducción de artefactos metálicos, también conocidos como Metal Artifact Reduction (MAR, por sus siglas en inglés) (4). Entre las soluciones comerciales destacan OMAR de Philips, IMAR de Siemens Healthineers, SEMAR de Canon y SmartMAR o MARS de GE Healthcare, entre otras (5–7). Los métodos clásicos, como la reconstrucción iterativa con ART (8) y la interpolación de sinogramas como NMAR (9), han demostrado ser eficaces en la supresión de artefactos secundarios, preservando la calidad de los bordes metálicos en las imágenes. Recientemente, la inteligencia artificial, especialmente a través de técnicas de aprendizaje profundo (Deep Learning), ha mostrado un notable avance en la corrección de artefactos metálicos mediante el uso de redes neuronales convolucionales (CNN) (10). Además, otros enfoques como la tomografía computarizada con energía dual (DECT) han reducido los artefactos en un 47% para

prótesis de cadera y en un 18% para implantes dentales (11). Por otro lado, la TC por conteo de fotones (PCCT) ha mostrado mejoras específicas al ajustar el nivel de energía (keV) en los procedimientos (12). También se han desarrollado enfoques híbridos que combinan métodos clásicos, aprendizaje profundo y energía dual, obteniendo resultados prometedores.

En el contexto peruano, se reportó que las imágenes afectadas por artefactos metálicos mejoraron en 24% y 48% a un nivel bueno y excelente, respectivamente, tras aplicar los métodos MAR (3). Otra investigación peruana hace mención que el software SEMAR mejoró la calidad de imagen en tomografías de cabeza y cuello en un 82%, con un nivel de confianza del 95%, lo que confirma su interpretabilidad diagnóstica en estudios con implantes dentales (13). El método Quad-Net se posiciona como el método más preciso, superando a DuDoNet y DANNet en métricas clave como RMSE (0.86), PSNR (43.45 dB) y SSIM (98.16%), lo que indica menor error, mejor calidad e interpretabilidad diagnóstica con mayor preservación estructural (14).

La presente revisión describe técnicas de reducción de artefactos metálicos en tomografía computarizada, destacando el impacto de tecnologías avanzadas como el aprendizaje profundo y el conteo de fotones en la calidad e interpretación diagnóstica.

II. OBJETIVOS

OBJETIVO GENERAL

Describir cómo los métodos clásicos e inteligencia artificial open source mejoran la calidad de imagen y la interpretabilidad diagnóstica en tomografía computarizada al reducir artefactos metálicos.

OBJETIVOS ESPECÍFICOS

1. Describir métodos clásicos de reducción de artefactos metálicos en TC.
2. Describir métodos basado en inteligencia artificial para reducción de artefactos metálicos en TC.
3. Describir la reducción de los artefactos metálicos al utilizar los métodos clásicos e inteligencia artificial.

III. CUERPO

CAPÍTULO I: ESTRATEGIA DE BÚSQUEDA

Bases de datos utilizadas

En este trabajo narrativo se realizó la búsqueda de literatura en inglés, en dos buscadores de datos: Pubmed y Google Académico. La fecha de búsqueda fue el 22 de enero del 2025. Además, se incluyó registros de artículos científicos identificados a partir de recomendación de expertos.

Términos utilizados

En la búsqueda de literatura se incluyeron los términos: "Metal Artifact Reduction", "Tomography, X-Ray Computed", "Algorithms", "Artificial Intelligence".

Fórmula de búsqueda

Todas las fórmulas de búsqueda pueden verse en el ANEXO 1

Elección de artículos

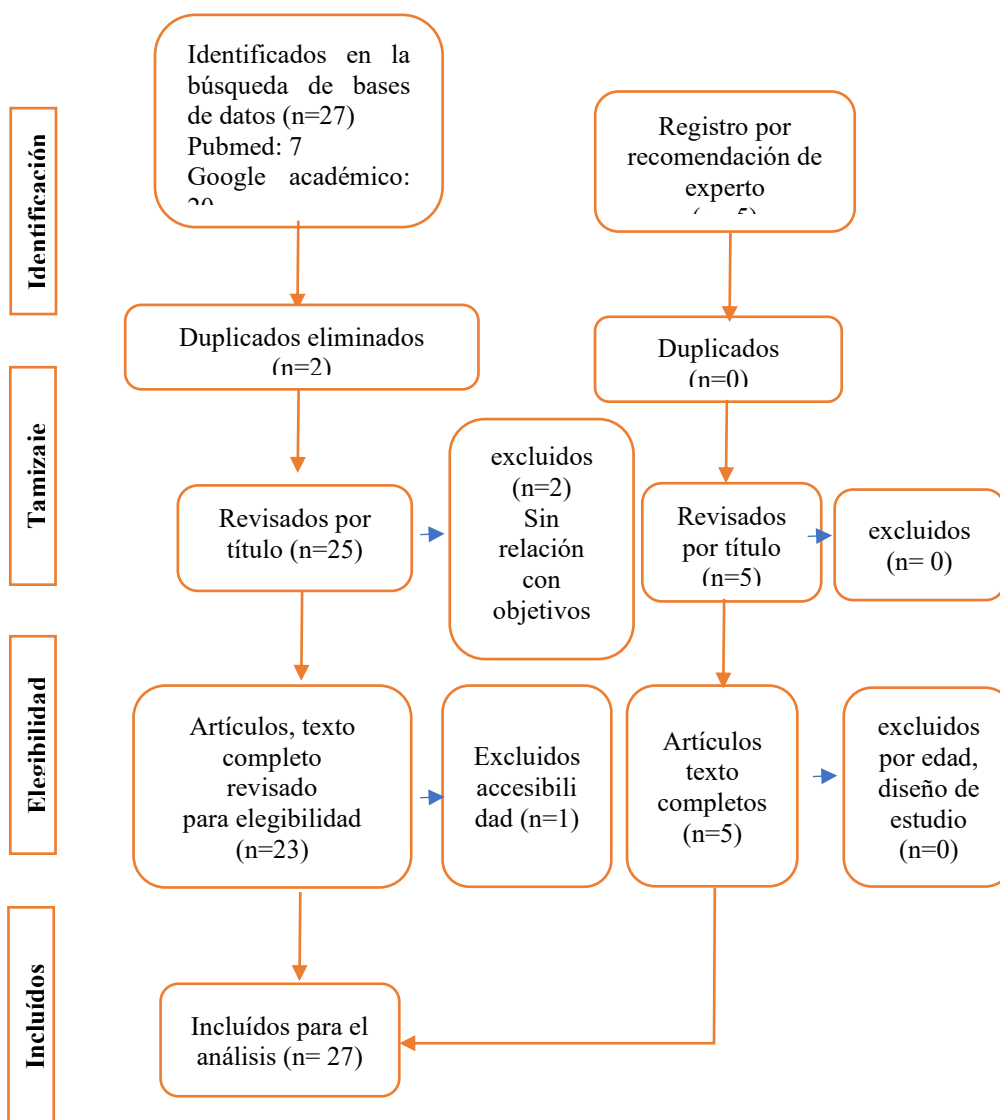
El presente estudio recopiló información reciente del 2010 al 2025, enfocado a la reducción de artefactos metálicos mediante métodos clásicos e inteligencia artificial en adultos. Se excluyeron investigaciones con otros tipos de adquisición de imágenes que no sean tomografía, así como los estudios duplicados.

Los artículos seleccionados, todos en idioma inglés, se identificaron mediante el gestor Zotero y se filtraron inicialmente por título y resumen para garantizar su relevancia. No fue un criterio de exclusión los artículos en español que fueran recomendados por expertos.

CAPÍTULO II. DESCRIPCIÓN DE HALLA ZGOS

Se identificaron 27 estudios en inglés, de los cuales 22 fueron seleccionados para revisión a texto completo y 5 fueron eliminados. Durante el proceso de selección, se excluyeron 2 por duplicidad, 2 por no estar directamente relacionados con los objetivos del estudio y 1 debido a la falta de acceso al contenido. Además, se incorporaron 5 artículos adicionales por recomendación de un experto en el área. En total, se consideraron 27 artículos para el presente trabajo académico.

Flujograma del proceso de recopilación de información y resultados.



Elaboración propia

HALLAZGOS

1. Tomografía Computarizada (TC)

La tomografía es una técnica de imagen basada en rayos X que permite obtener imágenes tridimensionales de diversas áreas anatómicas. Su evolución desde 1971 ha sido notable, pasando de imágenes axiales de baja resolución a sistemas avanzados con inteligencia artificial. Actualmente, tiene amplias aplicaciones en oncología, cardiología, traumatología y radiología intervencionista, entre otras especialidades (15).

Los avances tecnológicos han mejorado su calidad de imagen (Anexo 3), pero el aumento de implantes metálicos en pacientes ha afectado su rendimiento. Actualmente, alrededor del 21 % de las tomografías incluyen estos implantes, lo que puede perjudicar la calidad de las imágenes (1,16)

Los implantes metálicos pueden atenuar o bloquear los rayos X, generando datos deficientes que, al reconstruirse, producen artefactos en la imagen de la tomografía computarizada (TC) generando un diagnóstico poco fiable.

2. Artefactos Metálicos en Tomografía Computarizada (TC)

Los artefactos metálicos en CT son distorsiones visuales causadas por la interacción de los rayos X con objetos metálicos presentes en el campo de escaneo, como implantes quirúrgicos, dispositivos dentales, entre otros. Estos artefactos dificultan la evaluación diagnóstica al deformar la representación del tejido adyacente, haciendo poco fiable o imposible el análisis de estructuras óseas y tejidos blandos. En el anexo 4 se menciona las causas de los artefactos metálicos, definición y el efecto que se produce en la imagen.

- **Tipos de metales más usados en prótesis:**

En cuanto al tipo de metal, estudios han demostrado que los implantes de titanio generan menos artefactos que los de acero inoxidable o cromo-cobalto, sin comprometer la estabilidad ósea. Aunque materiales como el plástico eliminan por completo los artefactos, su durabilidad es limitada. En el anexo 5 se destaca al titanio por su menor rigidez, alta resistencia y biocompatibilidad, lo que lo convierte en una opción óptima para reducir distorsiones en tomografías en comparación del acero inoxidable y el Vitelio.

- **Tamaño de prótesis metálicas:**

El tamaño de una prótesis metálica influye directamente en la cantidad y severidad de los artefactos generados en la tomografía computarizada. Esto ocurre porque los objetos metálicos interfieren con la transmisión de los rayos X, generando distorsiones en la imagen.

Las prótesis pequeñas generan artefactos leves corregibles con calibraciones de atenuación. Las medianas, como placas ortopédicas, producen artefactos moderados que requieren interpolación en sinograma o reconstrucción iterativa. Mientras que las grandes, como prótesis de cadera, causan distorsiones severas que afectan el diagnóstico y la planificación de tratamientos, necesitando algoritmos avanzados de reducción de artefactos como reconstrucción iterativa o aprendizaje profundo (DLR).

En el Anexo 6 se da a conocer la categorización de los implantes de acuerdo con su tamaño: Los implantes grandes y densos, como artroplastias y dispositivos odontológicos, requieren energías más altas (120-200 keV) y pueden reducir artefactos hasta en un 90-100% con técnicas como MAR. En cambio, los implantes

medianos, como placas y tornillos, necesitan 110-190 keV, logrando reducciones de 40-70%. Los dispositivos cardiovasculares responden mejor a 100-120 keV, con mejoras de 20-60%, mientras que los dispositivos intracraneales muestran la menor reducción de artefactos (15-30%) incluso con técnicas avanzadas. En general, la combinación de energías óptimas y algoritmos de reducción de artefactos mejora significativamente la calidad de imagen, siendo más efectiva en implantes pequeños y menos en dispositivos grandes y críticos.(17)

Para mitigar estos inconvenientes, se han desarrollado diversas técnicas de reducción de artefactos metálicos, MAR estos son un desafío, ya que es difícil eliminar los artefactos sin perder detalles anatómicos (18). En esta revisión, clasificamos estos métodos en enfoques tradicionales o clásicos y aquellos basados en inteligencia artificial, estableciendo una comparación detallada para finalmente determinar cuál logra una reducción más efectiva de los artefactos metálicos.

3. Métodos Clásicos para la Reducción de Artefactos Metálicos en TC.

Dentro de esta evolución los algoritmos de reducción de artefactos metálicos, MAR han demostrado mejorar la calidad de imagen en tomografía computarizada (TC), optimizando el diagnóstico y la planificación en radioterapia (RT). Permitiendo corregir imprecisiones en los cálculos de dosis y mejorar la precisión del número CT (HU), cuyos valores pueden variar entre un 10–20% en diferentes regiones anatómicas. Sin embargo, pueden generar artefactos secundarios que afectan estructuras cercanas al metal, lo que podría comprometer la interpretación diagnóstica (19). A pesar de su eficacia, las técnicas MAR pueden introducir artefactos brillantes no deseados debido a segmentaciones imperfectas, por lo que

es necesario comparar las imágenes corregidas con las originales para evitar errores en el diagnóstico y la planificación.

Los artefactos metálicos afectan la calidad de la imagen en TC, dificultando la evaluación clínica. Ge et al reportaron un caso de pseudofractura de tornillo pedicular, donde una banda oscura en TC con MAR fue erróneamente interpretada como fractura. Las imágenes sin MAR confirmaron la integridad del tornillo, evidenciando limitaciones del algoritmo. Se recomienda contrastar las imágenes corregidas con las originales para evitar diagnósticos erróneos (20).

En otro estudio realizado por Pérez Mejía et al. Tuvo como muestra 50 imágenes de TC donde se confirmó que el software MARs mejora la interpretabilidad diagnóstica al reducir artefactos. Sin uso de MARs, las unidades Hounsfield (UH) en el área periprotésica promediaban -266.24 (hueso), -229.96 (partes blandas) y -217.36 (tejido graso), mejorando con MARs a 89.72, 39.48 y -76.04, respectivamente. Como resultado, el 48% de las imágenes pasó de deterioradas a excelente interpretación (3).

Para mitigar estos artefactos metálicos, se han desarrollado múltiples técnicas MAR con estrategias avanzadas, divididas en métodos basados en hardware y software:

a) Métodos basados en hardware para la reducción de artefactos metálicos en tomografía computarizada (TC):

Estos métodos optimizan la adquisición de imágenes para minimizar distorsiones antes del procesamiento digital. Entre ellos, DECT, Filtración espectral, modulación de la corriente del tubo y Monoenergético de Alta Energía (MonoE).

En el Anexo 7 se define los tipos de métodos basados en hardware. Asimismo, Kleber et al en su estudio hace mención que los métodos tradicionales, como

SEMAR, O-MAR e iMAR, estos no son completamente efectivos porque presentan limitaciones y no eliminan completamente los artefactos metálicos. Modelos basados en aprendizaje profundo (DL-MAR) muestran mejoras significativas al respecto (21). En la investigación de Chávarry Vargas, el software SEMAR mejoró la calidad de imagen en tomografías de cabeza y cuello en un 82%, con un nivel de confianza del 95%, lo que confirma su interpretabilidad diagnóstica en estudios con implantes dentales. (13).

Selles, Mark et al. Indica que los métodos tradicionales incluyen: el ajuste de voltaje (150 kVp) para mejorar la penetración, filtración con estaño para optimizar el espectro, MBIR para reducir artefactos mejor que FBP, y DECT para minimizar distorsiones con imágenes monoenergéticas (17). Gregor et al hace mención que algoritmos iterativos como SIRT y PSIRT pueden mejorar la calidad de imagen y reducir artefactos, lo cual es clave en la evaluación postquirúrgica con implantes metálicos. Además, su optimización computacional podría facilitar su implementación en entornos clínicos con restricciones de hardware (22).

b) Métodos basados en software para la reducción de artefactos metálicos en tomografía computarizada (TC):

La evolución de la reconstrucción de imágenes por TC ha avanzado significativamente para mejorar la calidad y reducir artefactos, especialmente en estudios de dosis baja. A lo largo del tiempo, se han desarrollado distintos métodos con ventajas y limitaciones. Ver anexo 8.

El método basado en software actúa durante el procesamiento y reconstrucción de imágenes para mejorar su calidad. Uno de los enfoques más utilizados es la interpolación de sinogramas MAR (21), que sustituye los datos afectados por el

metal con información de áreas cercanas, con variantes como NMAR, que usa píxeles no afectados, y FSMAR, que separa las frecuencias de la imagen para una corrección más precisa. Además, fabricantes como Siemens, Philips, GE y Canon han desarrollado algoritmos específicos para optimizar la calidad de imagen en distintos tipos de implantes metálicos. Otra técnica es la reconstrucción iterativa (IR) (23), donde modelos matemáticos, como MBIR, simulan la formación de la imagen para eliminar artefactos con mayor precisión. También existen métodos de segmentación y sustitución, que identifican y reemplazan el metal con valores interpolados antes de la reconstrucción. Estos métodos permiten mejorar la visualización de tejidos cercanos a los implantes, beneficiando aplicaciones como la radioterapia y el diagnóstico médico. En el anexo 9 se menciona estos métodos de manera didáctica.

4. Métodos Basados en Inteligencia Artificial (IA)

La IA especialmente el deep learning, ha revolucionado la tomografía computarizada mediante algoritmos que mejoran la interpretabilidad diagnóstica de las imágenes, reducen artefactos y ruido, optimizan la dosis de radiación y elevan la calidad diagnóstica. Actualmente a través de redes neuronales, estos métodos analizan datos complejos, permitiendo una reconstrucción más precisa y una automatización superior a los enfoques tradicionales.

4.1. Redes Neuronales (CNNs) y Aprendizaje Profundo

El término Deep Learning Reconstruction (DLR) se refiere a las técnicas de aprendizaje profundo aplicadas a la reducción de artefactos en TC. Según Koetzier et al. la reconstrucción basada en Deep learning ha logrado generar imágenes de

alta calidad con bajo ruido y resolución preservada, permitiendo una reducción de la dosis de radiación de hasta un 71% (23).

Tipos de Reconstrucción por Deep Learning (DLR)

DLR Indirecto

Este enfoque mejora distintas etapas de la reconstrucción mediante métodos tradicionales como la retroproyección filtrada (FBP) y la reconstrucción iterativa (IR). Además, puede optimizar los sinogramas, las imágenes o ambos en un modelo híbrido, empleando redes neuronales convolucionales (CNNs) para una mayor precisión. En su estudio Hui Tang et al menciona que el método basado en redes neuronales convolucionales (CNN) mejora la reducción de artefactos metálicos en tomografía computarizada de haz cónico (CBCT) dental, combinando segmentación, interpolación lineal (LI) y fusión de volúmenes con U-Net. Supera a FS-MAR y otros métodos, con NRMSD = 4,0196 (menor error) y SSIM = 0,9924 (alta fidelidad), optimizando imágenes clínicas y simuladas (24).

DLR Directo

Este método transforma directamente los sinogramas en imágenes sin depender de FBP o IR, logrando una reducción más eficiente de artefactos. Ejemplos destacados de esta técnica incluyen AUTOMAP e iRadonMAP.

4.2. Otras Técnicas Basada en IA

Además de las CNNs (24), se han desarrollado modelos avanzados como las Redes Generativas Antagónicas (GANs) (25), que aprenden a corregir artefactos mediante el entrenamiento con imágenes con y sin distorsiones.

4.3. Algoritmos Comerciales de Aprendizaje Profundo en TC

Diversas compañías han implementado algoritmos basados en deep learning para la reconstrucción de imágenes en TC.

En el anexo 10 las casas comerciales que hacen uso de aprendizaje profundo están representadas con las siguientes abreviaturas: AiCE = Motor Avanzado de Inteligencia Clear-IQ, DLR = reconstrucción mediante aprendizaje profundo, DLD = eliminador de ruido basado en aprendizaje profundo, FBP = retroproyección filtrada, HIR = reconstrucción iterativa híbrida, MBIR = reconstrucción iterativa basada en modelos. Algoritmos de aprendizaje profundo disponibles en el mercado (23).

4.4. Modelos de Aprendizaje Profundo Híbridos.

DECT (Dual-Energy CT): Se incluyen algunas técnicas híbridas que combinan DECT con IA para mejorar la reducción de artefactos metálicos, utilizando CNNs o modelos de atenuación profunda para refinar imágenes obtenidas con energía dual.

Combinación de CNNs con Métodos Clásicos: Técnicas que combinan DECT con redes neuronales para mejorar la calidad de imagen.

Modelos Basados en Atenuación Profunda: También pueden usar información de DECT para estimar mejor la atenuación del metal.

Modelo Quad-Net: es una red de aprendizaje profundo de cuatro dominios diseñada para reducir artefactos metálicos en tomografía computarizada (TC), integrando sinograma, imagen y espacios de Fourier para mejorar la calidad sin perder detalles estructurales.

En el anexo 11 Quad-Net es el método más eficiente, con 98.16% de preservación estructural, menor error (RMSE = 0.86) y mejor calidad de imagen (PSNR = 43.45 dB). DANNet mejora a DuDoNet, con 97.92% SSIM, menor error (0.86 RMSE) y 43.15 dB PSNR, pero aún con margen de mejora. DuDoNet tiene el peor desempeño, con 1.19 RMSE, menor calidad (40.74 dB PSNR) y menor preservación estructural (97.57% SSIM), siendo más propenso a ruido residual (14).

4.5. Métodos de IA Aplicados en el Dominio del Sinograma

Corrección de Artefactos en el Sinograma:

Se pueden usar los detectores avanzados EID (Energy-Integrating Detectors), PCD (Photon-Counting Detectors) y AMPS.

EID: Es el detector convencional en TC, pero puede ser usado junto con IA para mejorar la corrección de artefactos en el sinograma.

PCD (Photon-Counting Detector CT - PCCT): Un detector más avanzado que proporciona mejor resolución y reducción de ruido.

PCCT puede generar sinogramas más precisos y, al combinarse con IA, mejorar la eliminación de artefactos. Consideramos un estudio de una paciente postquirúrgica de 85 años con fusión espinal por fractura traumática y sospecha de aflojamiento de tornillos. En el corte axial de la 5ª vértebra cervical, la EID-CT muestra artefactos severos por los implantes, deteriorando la calidad de imagen y reduciendo la interpretabilidad diagnóstica. Tras el uso de PC-TC muestra menos artefactos, mejor visualización de la reabsorción ósea y evidencia de aflojamiento del tornillo derecho 130 keV (26). Mayor detalle ver el anexo 12.

Fusión de Imágenes Multi-Energéticas con IA:

DECT y PCCT pueden usarse para obtener múltiples imágenes con diferentes energías, que luego son combinadas con IA para mejorar la calidad final.

AMPS (Adaptive Metal Poisson-based Segmentation) utiliza un modelo basado en Poisson para mejorar la reconstrucción de imágenes en presencia de objetos metálicos, similar a otros métodos aplicados en el dominio del sinograma. Murphy et al propuso este método AM para mejorar la reconstrucción de imágenes en tomografía computarizada con objetos metálicos de pose desconocida, con una reducción de artefactos del 60% y un margen de error de un 4%, lo que mejora significativamente la interpretabilidad diagnóstica. Basado en un modelo de Poisson, optimiza la estimación de pose mediante descenso de gradiente, acelerando la convergencia y aumentando la calidad de imagen. Sus resultados sugieren una aplicación efectiva en entornos clínicos y de ingeniería, con potencial para extenderse a tomografía 3D (27).

Métodos con Mayor Reducción de Artefactos:

La reconstrucción con aprendizaje profundo, Metalny-Net (28) y DL (29) vs Imágenes Monoenergéticas logran una reducción del 50% de los artefactos metálicos, mejorando significativamente la calidad de imagen, interpretabilidad diagnóstica gracias a enfoques basados en deep learning. Por otro lado, iRadonMAP, con una reducción del 55%, se posiciona como el método con mejor desempeño, destacando por la reconstrucción y eliminación de distorsiones.

Métodos con Reducción Intermedia:

Las técnicas PC-CT y DECT, ambas con una reducción del 40% de artefactos, logran una mejora considerable al aprovechar imágenes monoenergéticas o la detección por conteo de fotones.

Métodos con Menor Reducción de Artefactos:

- DIOR (25%) → Aunque preserva detalles anatómicos, su impacto en la reducción de artefactos es limitado (30).
- DICDNet (30%) → Logra una mejora moderada, pero tiene el riesgo de pérdida de información en las imágenes (31).
- iCT-Net (35%) → Funciona en condiciones de adquisición de datos limitadas, pero su eficacia no es tan alta como otros métodos basados en deep learning (32).

En el anexo 13 se esquematiza la comparación de métodos de reducción de artefactos en TC y el porcentaje de reducción de artefacto en la imagen. Balt M et al. Desarrolla un método de reducción de artefactos metálicos en tomografía computarizada mediante modelado de tejidos y filtrado adaptativo combina tres pasos clave: filtrado adaptativo para reducir ruido en un 20%, clasificación de tejidos mediante clustering y corrección del sinograma para restaurar datos perdidos. En pruebas con maniqui redujo artefactos hasta 5000 HU, y en estudios clínicos mejoró la visualización ósea y de tejidos blandos sin distorsiones anatómicas. Aunque su eficacia disminuye en implantes grandes, su aplicación clínica podría optimizar la planificación de tratamientos (33).

Selles M et al. realizaron un estudio en 28 pacientes con artroplastia total de cadera (THA) unilateral, en el que compararon distintas técnicas de reconstrucción en tomografía computarizada (TC) para la reducción de artefactos metálicos. Evaluaron TC convencional, 130 keV monoE, O-MAR, 130 keV + O-MAR y DL-MAR, midiendo calidad de imagen, confianza diagnóstica y relación contraste-ruido (CNR). Los resultados mostraron que DL-MAR obtuvo la mejor puntuación en todos los parámetros, destacando por una mayor confianza diagnóstica en hueso

y tejidos blandos, menor ruido y mejor CNR ($p < 0.001$). A pesar de algunas limitaciones, DL-MAR se posicionó como la técnica más efectiva, con óptima interpretabilidad diagnóstica en estudios de pacientes con prótesis de cadera (34). En el anexo 14 se presenta los algoritmos de reducción de artefactos metálicos tradicionales (MAR no DL) con algoritmos basados en aprendizaje profundo (DL-MAR), se observa imagen con artefactos metálicos (a), la misma imagen antes de la corrección (b) y una versión corregida mediante un algoritmo de aprendizaje profundo (c). En el anexo 15 se observa que están relacionadas a la evaluación de cinco tipos de imágenes de TC en un paciente con artroplastia total de cadera: (a) convencional, (b) monoenergética de 130 keV, (c) monoE convencional con O-MAR, (d) monoE de 130 keV con O-MAR, y (e) con DL-MAR. Se definieron tres regiones de interés (ROI) en la imagen (a) y se copiaron a las demás reconstrucciones para medir valores de TC y ruido en Hounsfield Units (HU). Se utilizó una ventana de 1.600 de ancho y 400 HU de nivel.

La combinación de tomografía computarizada de doble energía (DECT) con algoritmos de reducción de artefactos metálicos (MAR) optimiza la calidad de imagen en presencia de implantes. Dependiendo del algoritmo y el nivel de energía monoenergética (MonoE), se pueden mejorar la visualización de tejidos blandos, la evaluación periprotésica y la reducción de artefactos en distintas aplicaciones médicas. En el anexo 16 se muestra los resultados de estas combinaciones. La combinación de DECT con algoritmos MAR mejora la reducción de artefactos, pero puede introducir artefactos secundarios. Se requieren estudios adicionales para optimizar su aplicación clínica.

Finalmente se presenta un enfoque híbrido de MAR que combina aprendizaje profundo y métodos convencionales para reducir artefactos metálicos en TC. Yu et al. Propone un método MAR basado en aprendizaje profundo, donde SinoNet restaura proyecciones afectadas, guiado por PriorNet, que genera imágenes previas con menos artefactos. La reconstrucción final con FBP mejora la continuidad y reduce nuevos artefactos, superando enfoques previos en TC simulada y real. El estudio no trabajó con una población de pacientes específicos, sino con imágenes de bases de datos médicas y simulaciones controladas para evaluar el rendimiento del método. En el anexo 17, consideramos una comparación visual con los diferentes métodos; las máscaras metálicas simuladas están coloreadas en rojo para una mejor visualización. Las imágenes (A1-A2) son imágenes de referencia. Se muestran los resultados de reducción de artefactos metálicos (MAR) de LI [2] (C1-C2), NMAR [15] (D1-D2), CNNMAR [11] (E1-E2), cGANMAR (F1-F2), DuDoNet (G1-G2) y el método (H1-H2). La ventana de visualización es de [-175, 275] HU (35).

IV. CONCLUSIONES

De acuerdo a la revisión narrativa realizada y en concordancia con los objetivos planteados se concluye lo siguiente: En el contexto peruano, investigaciones como las de Chávarry (13) Vargas y Pérez Mejía (3) han demostrado que los métodos de reducción de artefactos metálicos en TC, como SEMAR y MARs, mejoran significativamente la calidad de imagen, con incrementos del 82% y 48% en la interpretabilidad diagnóstica, respectivamente, cumpliendo con el objetivo de describir el impacto de los métodos clásicos.

A nivel global, los avances en inteligencia artificial open source han permitido desarrollar modelos más eficientes. Entre ellos, Quad-Net se posiciona como el método más preciso, superando a DuDoNet y DANNet en métricas clave como RMSE (0.86), PSNR (43.45 dB) y SSIM (98.16%), lo que indica menor error, mejor calidad de imagen y mayor preservación estructura.

La combinación de los métodos clásicos como la interpolación de sinogramas y la tomografía computarizada de energía dual (DECT) ha demostrado ser efectiva en la reducción de artefactos en prótesis de cadera y dispositivos dentales. No obstante, persisten desafíos como el alto costo computacional de los modelos de deep learning y la necesidad de optimizar su aplicación en entornos clínicos con hardware limitado.

V. REFERENCIAS BIBLIOGRÁFICAS

1. Boas FE, Fleischmann D. CT artifacts: causes and reduction techniques. *Imaging Med.* abril de 2012;4(2):229-40.
2. Gjestebj L, De Man B, Jin Y, Paganetti H, Verburg J, Giantsoudi D, et al. Metal Artifact Reduction in CT: Where Are We After Four Decades? *IEEE Access.* 2016;4:5826-49.
3. Mejía P, Ubaldo E. Utilidad del software de reducción de artefactos metálicos en tomografía computarizada aplicado a pacientes con implantes metálicos. Instituto Nacional de Enfermedades Neoplásicas, Lima 2018. Univ Nac Mayor San Marcos [Internet]. 2019 [citado 13 de enero de 2025]; Disponible en: <http://repositorioslatinoamericanos.uchile.cl/handle/2250/4883848>
4. Katsura M, Sato J, Akahane M, Kunimatsu A, Abe O. Current and Novel Techniques for Metal Artifact Reduction at CT: Practical Guide for Radiologists. *RadioGraphics* [Internet]. 12 de marzo de 2018 [citado 28 de noviembre de 2024]; Disponible en: <https://pubs.rsna.org/doi/10.1148/rg.2018170102>
5. Oonsiri S. Metal artifact reduction in computed tomography at head and neck region. *Chulalongkorn Univ Theses Diss Chula ETD* [Internet]. 1 de enero de 2017; Disponible en: <https://digital.car.chula.ac.th/chulaetd/518>
6. Aissa J, Boos J, Sawicki LM, Heinzler N, Krzemyk K, Sedlmair M, et al. Iterative metal artefact reduction (MAR) in postsurgical chest CT: comparison of three iMAR-algorithms. *Br J Radiol.* 1 de noviembre de 2017;90(1079):20160778.

7. Improvement of image quality and diagnostic confidence using Smart MAR – a projection-based CT protocol in patients with orthopedic metallic implants in hip, spine, and shoulder - Felix W Feldhaus, Georg Böning, Johannes Kahn, Uli Fehrenbach, Martin Maurer, Diane Renz, Florian Streitparth, 2020 [Internet]. [citado 16 de enero de 2025]. Disponible en: <https://journals.sagepub.com/doi/abs/10.1177/0284185120903446>
8. Ge Wang, Snyder DL, O’Sullivan JA, Vannier MW. Iterative deblurring for CT metal artifact reduction. *IEEE Trans Med Imaging*. octubre de 1996;15(5):657-64.
9. Arabi H, Zaidi H. Deep learning–based metal artefact reduction in PET/CT imaging. *Eur Radiol*. 2021;31(8):6384-96.
10. Utilidad del software de reducción de artefactos metálicos en tomografía computarizada aplicado a pacientes con implantes metálicos. Instituto Nacional de Enfermedades Neoplásicas, Lima 2018 [Internet]. [citado 28 de noviembre de 2024]. Disponible en: <https://1library.co/document/ydx39mez-reduccion-artefactos-metalicos-tomografia-computarizada-instituto-enfermedades-neoplasicas.html>
11. Bongers MN, Schabel C, Thomas C, Raupach R, Notohamiprodo M, Nikolaou K, et al. Comparison and Combination of Dual-Energy- and Iterative-Based Metal Artefact Reduction on Hip Prosthesis and Dental Implants. *PLoS ONE*. 24 de noviembre de 2015;10(11):e0143584.
12. Popp D, Sinzinger AX, Decker JA, Braun F, Bette S, Risch F, et al. Spectral metal artifact reduction after posterior spinal fixation in photon-counting detector CT datasets. *Eur J Radiol*. agosto de 2023;165:110946.

13. UNFV_FTM_Chavarry_Vargas_Ethel_Lucero_Titulo_profesional_2022.pdf [Internet]. [citado 1 de febrero de 2025]. Disponible en: https://repositorio.unfv.edu.pe/bitstream/handle/20.500.13084/6590/UNFV_FTM_Chavarry_Vargas_Ethel_Lucero_Titulo_profesional_2022.pdf?sequence=1&isAllowed=y
14. Li Z, Gao Q, Wu Y, Niu C, Zhang J, Wang M, et al. Quad-Net: Quad-Domain Network for CT Metal Artifact Reduction. *IEEE Trans Med Imaging*. mayo de 2024;43(5):1866-79.
15. Bq YD. Tomografía computarizada. Evolución, principios técnicos y aplicaciones *Computed Tomography. Evolution, technical principles and applications*. [citado 1 de febrero de 2025]; Disponible en: https://www.academia.edu/61968765/Tomograf%C3%ADa_computarizada_Evoluci%C3%B3n_principios_t%C3%A9cnicos_y_aplicaciones_Computed_Tomography_Evolution_technical_principles_and_applications
16. Kleber CE, Karius R, Naessens LE, Van Toledo CO, van Osch JA, Boomsma MF, et al. Advancements in supervised deep learning for metal artifact reduction in computed tomography: A systematic review. *Eur J Radiol*. 2024;111732.
17. Selles M, Osch JAC van, Maas M, Boomsma MF, Wellenberg RHH. Advances in metal artifact reduction in CT images: A review of traditional and novel metal artifact reduction techniques. *Eur J Radiol* [Internet]. 1 de enero de 2024 [citado 25 de enero de 2025];170. Disponible en: [https://www.ejradiology.com/article/S0720-048X\(23\)00590-9/fulltext](https://www.ejradiology.com/article/S0720-048X(23)00590-9/fulltext)

18. Tang H, Jiang S, Lin Y, Li Y, Bao X. An improved dual-domain network for metal artifact reduction in CT images using aggregated contextual transformations. *Phys Med Biol.* agosto de 2023;68(17):175021.
19. Selles M, Wellenberg RHH, Slotman DJ, Nijholt IM, van Osch JAC, van Dijke KF, et al. Image quality and metal artifact reduction in total hip arthroplasty CT: deep learning-based algorithm versus virtual monoenergetic imaging and orthopedic metal artifact reduction. *Eur Radiol Exp.* 14 de marzo de 2024;8(1):31.
20. Ge S, Kumar N, Hallinan JTPD. Pedicle Screw Pseudofracture on Computed Tomography Secondary to Metal Artifact Reduction. *Diagnostics.* enero de 2024;14(1):108.
21. Kleber CEJ, Karius R, Osch JAC van, Boomsma MF, Heemskerk JWT, Molen AJ van der. Advancements in supervised deep learning for metal artifact reduction in computed tomography: A systematic review. *Eur J Radiol* [Internet]. 1 de diciembre de 2024 [citado 25 de enero de 2025];181. Disponible en: [https://www.ejradiology.com/article/S0720-048X\(24\)00448-0/fulltext](https://www.ejradiology.com/article/S0720-048X(24)00448-0/fulltext)
22. Gregor J, Benson T. Computational Analysis and Improvement of SIRT. *IEEE Trans Med Imaging.* julio de 2008;27(7):918-24.
- VI. 23. Koetzier LR, Mastrodicasa D, Szczykutowicz TP, van der Werf NR, Wang AS, Sandfort V, et al. Deep Learning Image Reconstruction for CT: Technical Principles and Clinical Prospects. *Radiology.* marzo de 2023;306(3):e221257.

23. Tang H, Lin YB, Jiang SD, Li Y, Li T, Bao XD. A new dental CBCT metal artifact reduction method based on a dual-domain processing framework. *Phys Med Biol*. 17 de agosto de 2023;68(17).
24. Data and Image Domain Deep Learning for Computational Imaging - ProQuest [Internet]. [citado 28 de febrero de 2025]. Disponible en: <https://www.proquest.com/openview/09bee6ae583ac87a632aa9e8e5ebb4c4/1?pq-origsite=gscholar&cbl=18750&diss=y>
25. Rau A, Straehle J, Stein T, Diallo T, Rau S, Faby S, et al. Photon-Counting Computed Tomography (PC-CT) of the spine: impact on diagnostic confidence and radiation dose. *Eur Radiol*. 1 de agosto de 2023;33(8):5578-86.
26. Murphy RJ, Yan S, O'Sullivan JA, Snyder DL, Whiting BR, Politte DG, et al. Pose estimation of known objects during transmission tomographic image reconstruction. *IEEE Trans Med Imaging*. octubre de 2006;25(10):1392-404.
27. Zhang H, Liu B, Yu H, Dong B. MetaInv-Net: Meta Inversion Network for Sparse View CT Image Reconstruction. *IEEE Trans Med Imaging*. febrero de 2021;40(2):621-34.
28. Xu JJ, Lönn L, Budtz-Jørgensen E, Hansen KL, Ulriksen PS. Quantitative and qualitative assessments of deep learning image reconstruction in low-keV virtual monoenergetic dual-energy CT. *Eur Radiol*. 1 de octubre de 2022;32(10):7098-107.
29. Hu D, Zhang Y, Liu J, Luo S, Chen Y. DIOR: Deep Iterative Optimization-Based Residual-Learning for Limited-Angle CT Reconstruction. *IEEE Trans Med Imaging*. julio de 2022;41(7):1778-90.

30. Wang H, Li Y, He N, Ma K, Meng D, Zheng Y. DICDNet: Deep Interpretable Convolutional Dictionary Network for Metal Artifact Reduction in CT Images. *IEEE Trans Med Imaging*. abril de 2022;41(4):869-80.
31. Tao X, Wang Y, Lin L, Hong Z, Ma J. Learning to Reconstruct CT Images From the VVBP-Tensor. *IEEE Trans Med Imaging*. noviembre de 2021;40(11):3030-41.
32. Bal M, Spies L. Metal artifact reduction in CT using tissue-class modeling and adaptive prefiltering. *Med Phys*. agosto de 2006;33(8):2852-9.
33. Selles M, Wellenberg RHH, Slotman DJ, Nijholt IM, van Osch JAC, van Dijke KF, et al. Image quality and metal artifact reduction in total hip arthroplasty CT: deep learning-based algorithm versus virtual monoenergetic imaging and orthopedic metal artifact reduction. *Eur Radiol Exp*. 14 de marzo de 2024;8(1):31.
34. Yu L, Zhang Z, Li X, Xing L. Deep Sinogram Completion With Image Prior for Metal Artifact Reduction in CT Images. *IEEE Trans Med Imaging*. enero de 2021;40(1):228-38.
35. Wellenberg RHH, Boomsma MF, Van Osch JAC, Vlassenbroek A, Milles J, Edens MA, et al. Quantifying metal artefact reduction using virtual monochromatic dual-layer detector spectral CT imaging in unilateral and bilateral total hip prostheses. *Eur J Radiol*. marzo de 2017;88:61-70.
36. Gjestebj L, De Man B, Jin Y, Paganetti H, Verburg J, Giantsoudi D, et al. Metal Artifact Reduction in CT: Where Are We After Four Decades? *IEEE Access*. 2016;4:5826-49.

ANEXOS

Anexo 1: Enfoque de búsqueda de población, concepto, contexto.

| POBLACIÓN | CONCEPTO | CONTEXTO |
|---|--|--|
| Estudios de pacientes adultos que se han sometido a estudios de tomografía computarizada con artefactos metálicos visibles en las imágenes. | Los algoritmos clásicos o con inteligencia artificial reducen los artefactos metálicos en la tomografía para un mejor diagnóstico. | Mejorar la precisión en TC reduciendo artefactos metálicos |
| "Reducción de Artefactos Metálicos en Tomografía Computarizada: Métodos Clásicos e Inteligencia Artificial Open Source" | | |

Anexo 2: Palabras clave / Descriptores

| NÚMERO | BÚSQUEDA PUBMED | CANTIDAD |
|-------------------------------|--|----------|
| #1 | " Metal Artifact Reduction" | 916 |
| #2 | "Tomography, X-Ray Computed" | 434.089 |
| #3 | "Algorithms" | 430,323 |
| #4 | " Artificial Intelligence" | 7115.287 |
| #1 AND #2 | " Metal Artifact Reduction" AND "Tomography, X-Ray Computed" | 410 |
| #2 AND #3 | "Tomography, X-Ray Computed" AND "Algorithms" | 15,569 |
| #3 AND #4 | "Algorithms" AND " Artificial Intelligence " | 31.285 |
| #1 AND #2 AND #3 AND #4 | "Metal Artifact Reduction" AND "Tomography, X-Ray Computed" AND "Algorithms" AND "Artificial Intelligence" | 7 |

| NÚMERO | BÚSQUEDA GOOGLE SCHOLAR | CANTIDAD |
|-------------------------------|--|------------|
| #1 | " Metal Artifact Reduction" | 11,600 |
| #2 | "Tomography, X-Ray Computed" | 30,800 |
| #3 | "Algorithms" | 5,880,000 |
| #4 | " Artificial Intelligence " | 4,340,000 |
| #1 AND #2 | " Metal Artifact Reduction" AND "Tomography, X-Ray Computed" | 145 |
| #2 AND #3 | "Tomography, X-Ray Computed" AND "Algorithms" | 3210 |
| #3 AND #4 | "Algorithms" AND " Artificial Intelligence " | 23,220,000 |
| #1 AND #2 AND #3 AND #4 | " Metal Artifact Reduction" AND "Tomography, X-Ray Computed" AND "Algorithms" AND " Artificial Intelligence " | 20 |

Anexo 3: Evolución de la tomografía

| GENERACIÓN | CARACTERÍSTICA |
|---------------------------------------|--|
| Primera generación (1971) | <ul style="list-style-type: none"> ▪ Escáner EMI (primer tomógrafo clínico). ▪ Capturaba imágenes cerebrales en aproximadamente 4 minutos con tiempos de cálculo de 7 minutos por imagen. |
| Segunda generación (1976) | <ul style="list-style-type: none"> ▪ Incorporación de escáneres axiales con una única fila de detectores. ▪ Permite la exploración de cualquier parte del cuerpo. |
| Tercera generación (1986) | <ul style="list-style-type: none"> ▪ Aparición de escáneres helicoidales o espirales. ▪ Permiten la obtención continua de imágenes mientras la camilla del paciente se mueve. |
| Cuarta generación (finales de los 90) | <ul style="list-style-type: none"> ▪ Escáneres multidetectores con 4 filas activas (posteriormente 16, 64 filas). ▪ Mejora significativa en la resolución y tiempos más cortos de adquisición. |

Quinta generación:
Tomografía volumétrica (2007)

- Escáneres con hasta 320 filas de detectores.
- Adquisición de imágenes de órganos completos (corazón, cerebro) en una sola rotación.

Innovaciones recientes

- Tomógrafos de doble fuente: con dos tubos de rayos X, ideales para estudios cardíacos rápidos.
- Tomografía dinámica (4D): Seguimiento del movimiento de órganos y la perfusión de tejidos.
- Fluoroscopia TC: Para procedimientos intervencionistas en tiempo real.
- Tomografía de doble energía: Diferenciación precisa de tejidos y eliminación de estructuras óseas.

La evolución tecnológica ha mejorado la resolución espacial, tiempos de adquisición, reducción de dosis de radiación y ha permitido la integración con otras modalidades como PET y SPECT.

Anexo 4: Principales causas de los artefactos metálicos que distorsiona la calidad de las imágenes.

| CAUSA DEL ARTEFACTO | DEFINICIÓN | EFECTO EN LA IMAGEN |
|-------------------------------|---|---|
| Endurecimiento del Haz | Absorción desigual de los rayos X poli energéticos. | Rayas oscuras entre objetos de alta atenuación. |
| Dispersión | Cambio de dirección de los fotones, causando detección errónea. | Rayas blancas y subestimación de la absorción. |
| Inanición de Fotones | Déficit de fotones en metales densos y de alto número atómico. | Aumento del ruido y datos faltantes en la proyección. |
| Efectos de Borde | Interfaces marcadas entre tejidos de diferente atenuación. | Rayas brillantes u oscuras en los bordes. |

Elaboración propia traducido al español y adaptado de Wellenberg et al (36)

Anexo 5: Tipos de metales que mejor se adaptan a la TC.

| Característica | Acero Inoxidable | Titanio | Vitalio |
|----------------------------|-------------------------|----------------|----------------|
| Rigidez | Alta | Baja | Media |
| Resistencia | Media | Alta | Media |
| Resistencia a la corrosión | Baja | Alta | Media |
| Biocompatibilidad | Baja | Alta | Media |

Elaboración propia traducido al español y adaptado de Gjestebj et al (37)

Anexo 6: Categorización de implantes y técnicas de reducción de artefactos metálicos

| TAMAÑO Y TIPO DE IMPLANTE | | IMÁGENES MONOENERGÉTICAS (MONO E) | RECOMENDACIÓN DE ALGORITMO MAR | % DISTORSIÓN DE LA IMAGEN |
|---|--|--------------------------------------|-----------------------------------|------------------------------|
| Implantes grandes Alta densidad Artefactos severos | Artroplastia de cadera | 120-200 keV++ +++ | 140 keV + MAR | 90-100% |
| | Artroplastia de rodilla | 120-140 keV+ +++ | | 85-95% |
| | Artroplastia de hombro | 130 keV++ +++ | | 80-90% |
| | Artroplastia de tobillo | 105-150 keV++ +++ | | 70-85% |
| | Odontología | 130-200 keV ++ | | |
| Implantes medianos - materiales de osteosíntesis Densidad media | Placas ortopédicas | 110-180 keV++ | 130 keV MonoE | 60-70% |
| | Clavos intramedulares | +/- 130-190 keV++ | | 50-65% |
| | Tornillos ortopédicos | +/- 109-144 keV++ | | 45-60% |
| | Tornillos de columna | +/- 105-200 keV++ +* | | 40-55% |
| Dispositivo cardiaco electrónico – Baja densidad Artefactos medianos | Dispositivo | +/- 140-200 keV++ ++ | 100 keV + MAR | 50-60% |
| | Pistas | 100 keV++ ++ | | 30-50% |
| Metal cardiovascular Artefactos medianos y pequeños | Reemplazo de válvula aórtica | 100 keV++ | 100 keV monocristalino | 40-50% |
| | Alambres esternales | +/- 100-200 keV++ | | 30-45% |
| | Stent de arteria coronaria | +/- 100-120 keV++ | | 25-40% |
| | Clips de derivación | +/- 100-120 keV++ | | 20-35% |
| Dispositivos intracraneales Pequeños artefactos metálicos Baja densidad | Bobinas y clips intracraneales (sin contraste) | +/- 100-200 keV++ | 140 keV + MAR65 | 15-25% |
| | Bobinas y clips intracraneales (CTA) | ++ 40-75 keV+ | | |

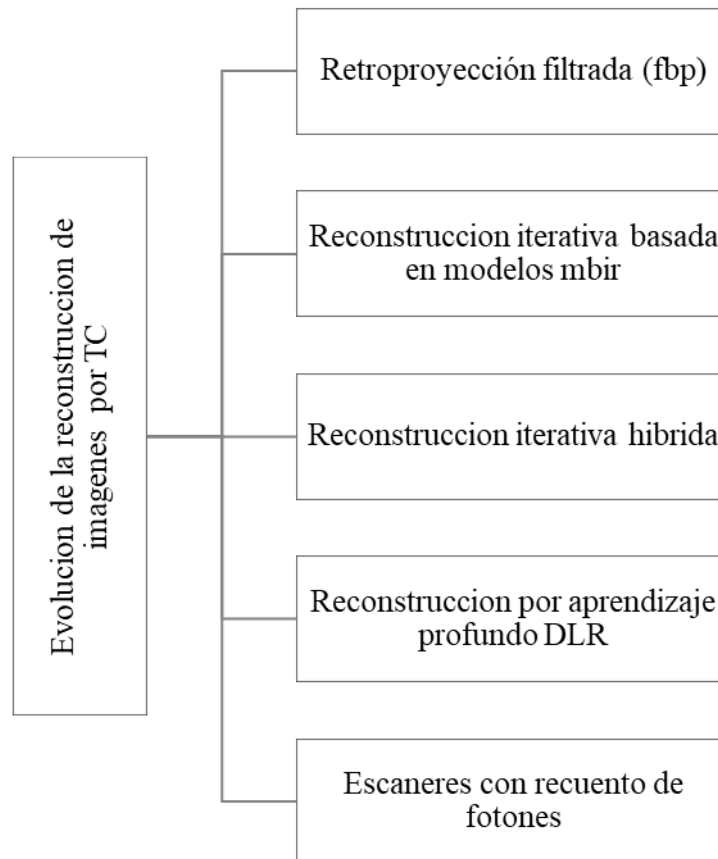
(+) Pequeña reducción de artefactos metálicos, (++) Reducción media de artefactos metálicos, (+++) Gran reducción de artefactos metálicos, (+/-) el valor agregado es cuestionable, (*) Puede introducirse artefactos secundarios graves. *Elaboración propia traducido al español y adaptado de selles et al (17)*

Anexo 7: Métodos basados en hardware (adquisición de imágenes).

| ORIGEN DEL MÉTODO | TIPO | DEFINICIÓN |
|--|---|--|
| Métodos basados en hardware (adquisición de imágenes) | Tomografía Computarizada de Energía Dual (DECT) | Usa dos niveles de energía para mejorar la diferenciación de materiales y reducir artefactos. |
| | Filtración Espectral | Modificación de los espectros de rayos X mediante filtros especiales para reducir la atenuación por metales. |
| | Modulación de la corriente del tubo de rayos X | Ajusta la dosis según la atenuación del material, optimizando la calidad de imagen. |
| | Monoenergético de Alta Energía (MonoE) | Reduce el endurecimiento del haz. |

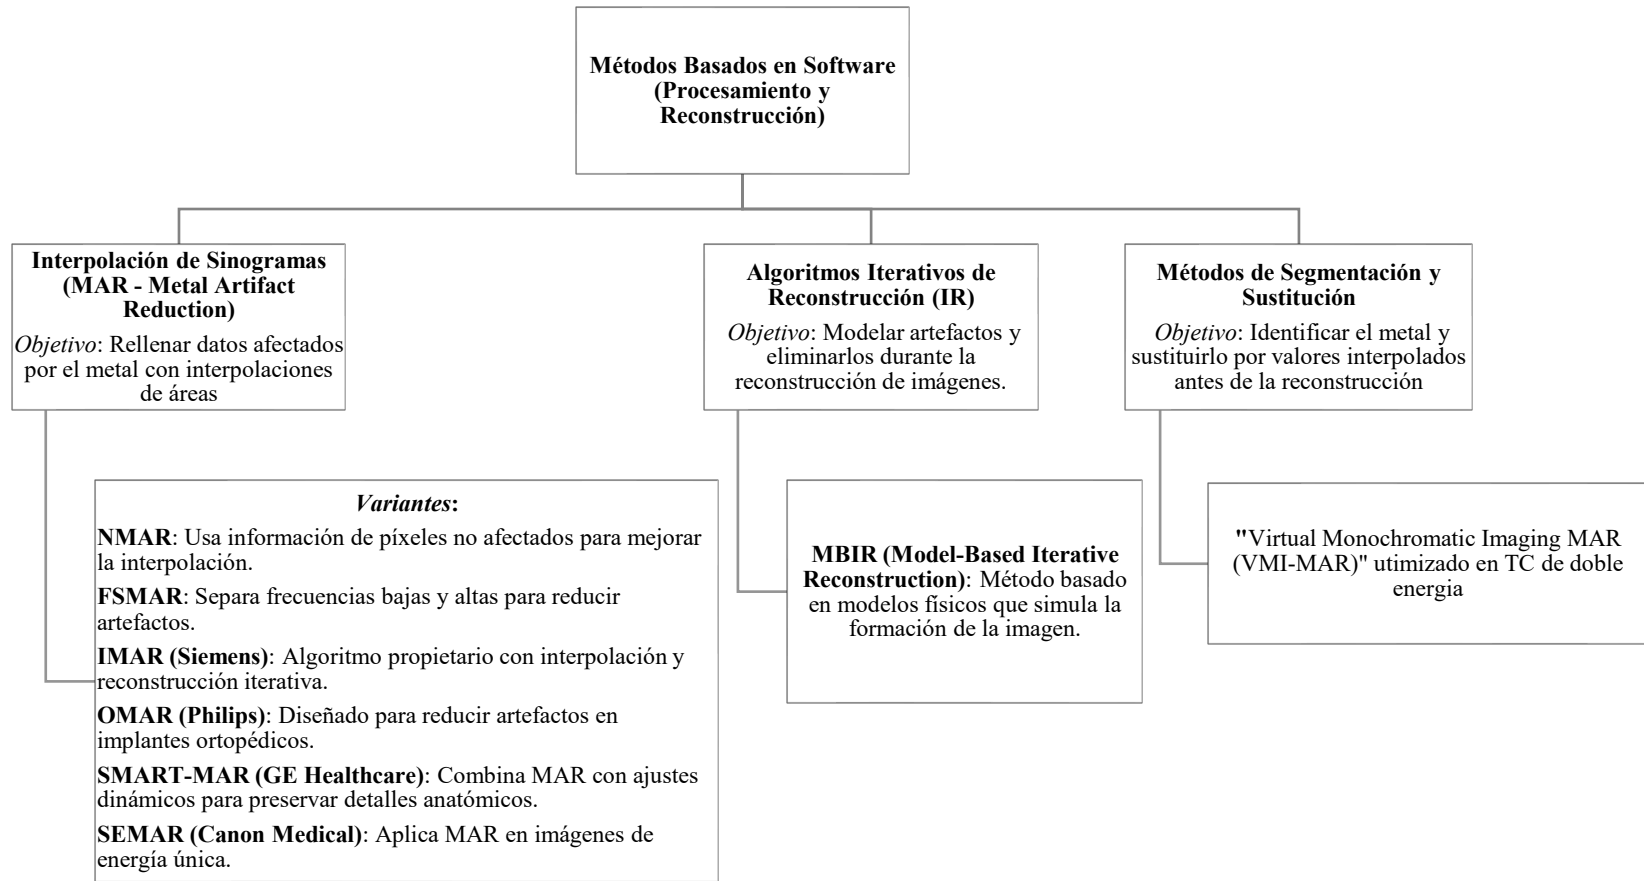
Elaboración propia adaptado de Selles et al (17)

Anexo 8: Evolución de la reconstrucción de imágenes por tomografía computarizada.



Elaboración propia adaptado de Koetzier at al. (23)

Anexo 9: Métodos basados en software (procesamiento y reconstrucción)



Elaboración propia adaptado de Selles et al (17)

Anexo 10: Uso de Aprendizaje Profundo en TC: Casas Comerciales

| NOMBRE DE ALGORITMO | DESARROLLO DE ALGORITMO | CLASE DE ALGORITMO | TIPO DE ALGORITMO | IMÁGENES DE LA VERDAD FUNDAMENTAL |
|----------------------------|--------------------------------|---------------------------|-------------------------------|--|
| Verdadera Fidelidad | Atención Sanitaria GE | DLR | Directo | FBP |
| AiCE | Sistema Medico Canon | DLR | Indirecto, basado en imágenes | MBIR |
| Imagen Precisa | Atención Sanitaria Phillips | DLR | Directo | FBP |
| Brillo de Pixeles | AlgoMedica | DLD | Eliminador de ruido de imagen | FBP, HIR, MBIR |
| ClariCT.AI | ClariPi | DLD | Eliminador de ruido de imagen | FBP |

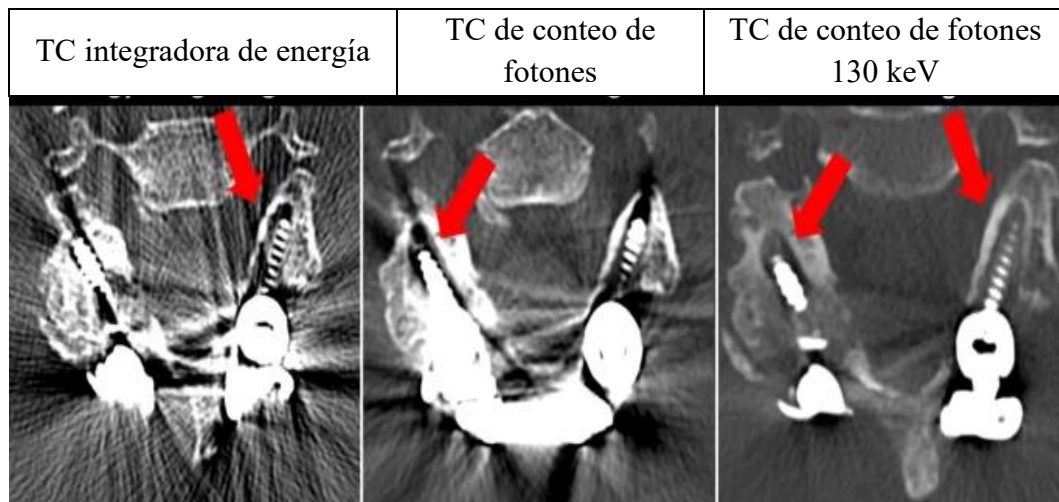
Elaboración propia traducido al español y adaptado de koetzier et al (23)

Anexo 11: Comparación de Quad-Net, DuDoNet y DANNet.

| <i>MÉTRICAS DE EVALUACIÓN DE CALIDAD DE IMAGEN</i> | | | | |
|--|---|--------------------------------------|--|---|
| MÉTODO | RMSE (ERROR CUADRÁTICO MEDIO) | PSNR (RELACIÓN SEÑAL-RUIDO EN DB) | SSIM (ÍNDICE DE SIMILITUD ESTRUCTURAL) | INTERPRETACIÓN |
| DuDoNet | 1.19 (mayor error) | 40.74 dB (menor calidad de imagen) | 97.57% (menor preservación estructural) | Más propenso a errores en la reconstrucción, con mayor ruido residual. |
| DANNet | 0.86 (menor error que DuDoNet) | 43.15 dB (mejor calidad que DuDoNet) | 97.92% (mayor similitud estructural) | Reduce artefactos mejor que DuDoNet, pero aún con margen de mejora. |
| Quad-Net | 0.86 (igual error que DANNet, pero con mejor PSNR y SSIM) | 43.45 dB (mejor calidad de imagen) | 98.16% (máxima preservación estructural) | Mejor rendimiento global, con menor ruido y mejor conservación de detalles. |

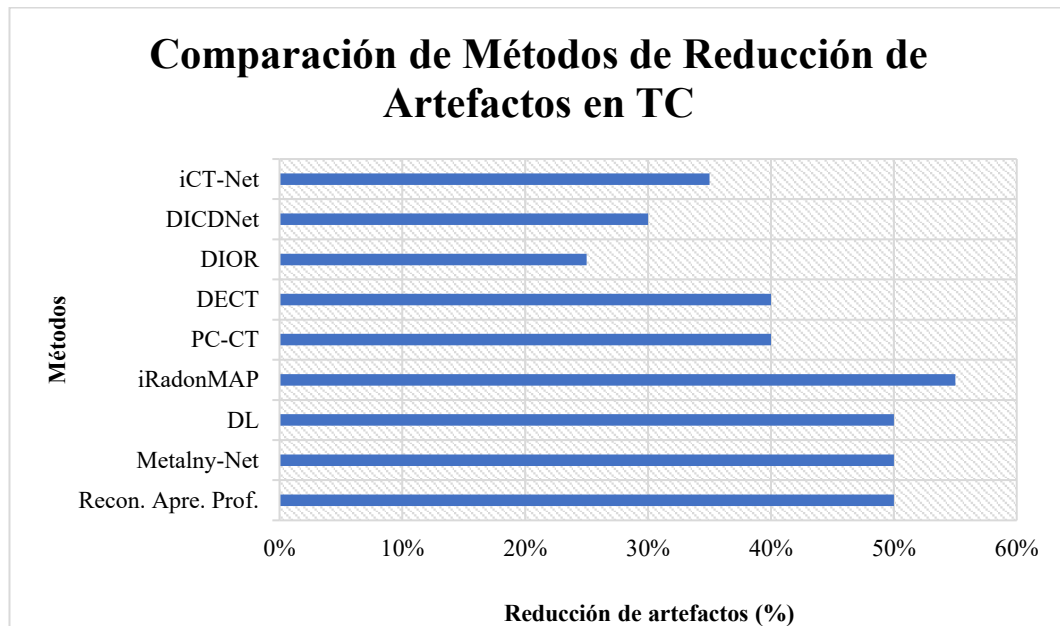
Elaboración propia adaptado de Zion L et al (14)

Anexo 12: Utilidad de PC- CT + 130 keV




Elaboración propia traducido al español y adaptado de Rau et al (26)

Anexo 13: Comparación de Métodos de Reducción de Artefactos en TC



Elaboración propia


Anexo 14: Calidad de imagen usando DL



Elaboración propia, adaptado de kleber CEJ et al.(21)

Anexo 15: Cinco tipos de imágenes de TC en un paciente con artroplastia total de cadera

| Convencional | 130 kv | Convencional + OMAR | 130 kev + OMAR | DL-MAR |
|--------------|--------|---------------------|----------------|--------|
|--------------|--------|---------------------|----------------|--------|




Elaboración propia traducido al español y adaptado de Selles et al (34)

Anexo 16: Combinación de DECT con MAR

| Combinación | Resultados |
|--------------------------------------|--|
| O-MAR + MonoE (140-200 keV) | Reducción de artefactos en implantes THA (Artroplastia total de cadera) y mejor evaluación de órganos pélvicos |
| MARS + MonoE (120-140 keV) | Mejora en la evaluación de tejido óseo periprotésico |
| iMAR + MonoE (130 keV) | Mayor reducción de artefactos en implantes TSA (Artroplastia total de hombro) y TAA (Artroplastia total de tobillo). |
| O-MAR + MonoE (100, 140, 200 keV) | Reducción de artefactos en implantes dentales y mejor visibilidad de tejidos blandos |
| MARS + MonoE (40-75 keV) | Mejor contraste de vasos en CTA (Angiografía por tomografía computarizada) con clips y coils intracraneales |

Elaboración propia traducido al español y adaptado de Selles, Mark et al.(17)

Anexo 17: Comparación de imágenes tomográficas con diferentes métodos de reducción de artefacto de imagen:



Elaboración propia traducido al español y adaptado de Yu L et al (35).

Anexo 18: Métodos de evaluación de la calidad e interpretabilidad de imagen en la reducción de artefactos:

| Método de evaluación | | Descripción |
|---|--|--|
| Evaluación por expertos | Evaluación por expertos radiológicos | Radiólogos califican la calidad de imagen en una escala (ej. 1-5 o 1-10). También pueden evaluar la confianza diagnóstica antes y después de aplicar la reducción de artefactos. |
| | Índice de Similitud Estructural (SSIM) | Mide la similitud entre la imagen corregida y la imagen ideal sin artefactos, evaluando aspectos como contraste, estructura y luminancia. |
| Métricas de calidad de imagen objetivas | Relación Señal-Ruido (SNR) | Evalúa cuánto ruido sigue presente en la imagen, midiendo la proporción entre la señal útil y el ruido de fondo. |
| | Relación Contraste-Ruido (CNR) | Mide la capacidad de la imagen para distinguir estructuras anatómicas, comparando el contraste entre regiones de interés y el ruido presente. |
| | Raíz del Error Cuadrático Medio (RMSE) | Compara las diferencias entre la imagen corregida y una imagen de referencia, cuantificando el error entre ambas. |

Elaboración propia