

**Evaluación de prototipos de software open source para corrección de artefactos
en imágenes de radiografía digital**

Carlos Andrés Gallego Muñoz

Deisy Yolima López Pantoja

Jean Pool Quesada Isaza

Liliana Valdez

Maylin Mejia Caicedo

Asesor

Edna Rocío Jamaica Guío

Universidad Nacional Abierta y a Distancia – UNAD

Escuela de ciencias de la salud ECISA

Tecnología en Radiología e Imágenes Diagnósticas

2026

Agradecimientos

Agradecemos a las personas que hicieron parte de este proceso académico, no solo por los conocimientos compartidos, sino también por los desafíos que impulsaron nuestro aprendizaje y crecimiento profesional.

Agradecemos a los docentes de la Tecnología en Radiología e Imágenes Diagnósticas de la UNAD, quienes contribuyeron a nuestra formación y fortalecieron las competencias que hoy nos permiten culminar esta etapa.

A nuestras familias y seres cercanos, gracias por comprender las horas de estudio, los momentos de esfuerzo y la dedicación requerida para alcanzar esta meta.

Finalmente, agradecemos a cada integrante de este grupo de trabajo, porque este proyecto es el resultado de la suma de diferentes ideas, experiencias y capacidades que convergieron en un mismo propósito.

Dedicatoria

Este trabajo está dedicado a las metas que parecían lejanas y que, con esfuerzo constante, terminaron convirtiéndose en realidad.

También se dedica a todos aquellos estudiantes que equilibran responsabilidades personales, laborales y académicas mientras persiguen un objetivo profesional. Que este logro sea una muestra de que la constancia puede transformar los desafíos en oportunidades de crecimiento.

Más que un punto de llegada, este proyecto representa el inicio de nuevos aprendizajes, compromisos y aportes a la profesión de Radiología e Imágenes Diagnósticas.

Resumen

La presencia de artefactos en las imágenes de radiografía digital constituye un desafío para la calidad diagnóstica, ya que puede alterar la representación de las estructuras anatómicas y afectar la interpretación clínica. Frente a esta problemática, diversas herramientas basadas en procesamiento digital de imágenes e inteligencia artificial han sido desarrolladas para apoyar la detección y corrección automatizada de estas alteraciones. La presente investigación tuvo como objetivo analizar el desempeño de prototipos de software open source orientados a la corrección de artefactos en imágenes radiológicas, mediante una revisión sistemática de literatura científica publicada en los últimos años. Se examinaron diferentes soluciones tecnológicas, considerando sus fundamentos técnicos, métricas de rendimiento, ventajas operativas, limitaciones y nivel de aplicabilidad en entornos clínicos.

Los resultados evidencian que las herramientas de código abierto han alcanzado avances significativos en la reducción de artefactos y el mejoramiento de la calidad de imagen, especialmente cuando incorporan modelos de aprendizaje profundo. Asimismo, se identificaron oportunidades relacionadas con la validación clínica, la estandarización de metodologías y la integración de estas soluciones en los flujos de trabajo radiológicos. Se concluye que el software open source representa una alternativa técnicamente viable y de amplia accesibilidad para fortalecer los procesos de control de calidad en radiología digital, favoreciendo el desarrollo de soluciones innovadoras y adaptables a diferentes contextos asistenciales.

Palabras Clave: radiología digital, artefactos radiológicos, software open source, inteligencia artificial, procesamiento digital de imágenes.

Abstract

The presence of artifacts in digital radiography images represents a significant challenge for diagnostic quality, as it may alter the visualization of anatomical structures and affect clinical interpretation. In response to this issue, various tools based on digital image processing and artificial intelligence have been developed to support the automated detection and correction of these image distortions. The objective of this study was to analyze the performance of open-source software prototypes designed for artifact correction in radiographic images through a systematic review of recent scientific literature. Different technological solutions were examined considering their technical foundations, performance metrics, operational advantages, limitations, and applicability within clinical environments. The findings indicate that open source tools have achieved significant progress in artifact reduction and image quality enhancement, particularly when incorporating deep learning models. Furthermore, opportunities were identified regarding clinical validation, methodological standardization, and the integration of these solutions into radiological workflows. In conclusion, open-source software represents a technically viable and highly accessible alternative for strengthening quality control processes in digital radiology, promoting the development of innovative and adaptable solutions for diverse healthcare settings.

Keywords: Digital radiology, radiographic artifacts, open source software, artificial intelligence, digital image processing.

Contenido

Introducción	10
Planteamiento del Problema.....	12
Justificación.....	15
Objetivos	18
Objetivo General.....	18
Objetivos Específicos	18
Marco Teórico	19
Artefactos en Imágenes de Radiografía Digital.....	19
<i>Origen y Clasificación de los Artefactos</i>	19
<i>Impacto de los Artefactos sobre la Calidad Diagnóstica</i>	20
Necesidad de Estrategias para Corrección y Detección de Artefactos	22
Métodos para la Detección y Corrección de Artefactos	22
<i>Métodos Manuales para la Detección de Artefactos</i>	23
<i>Métodos Automatizados para la Detección de Artefactos</i>	24
Inteligencia Artificial y Aprendizaje Profundo en Radiología	26
Aprendizaje Automático y Aprendizaje Profundo	27
Redes Neuronales Convolucionales para el Análisis de Imágenes Médicas	28
Aplicaciones de la Inteligencia Artificial en la Detección y Corrección de Artefactos.....	29
Evaluación de Prototipos de Software para Análisis de Imágenes Médicas	30
<i>Métricas para la Evaluación del Desempeño</i>	31
<i>Indicadores Utilizados en la Detección y Corrección de Artefactos</i>	32
Comparación entre Métodos Manuales y Automatizados	33

Software Open Source en el Desarrollo de Herramientas para Radiología Digital...	34
<i>Fundamentos del Software Open Source</i>	37
<i>Ventajas del Software Open Source en Investigación y Salud</i>	38
<i>Aplicaciones del Software Open Source en el Procesamiento de Imágenes</i>	
<i>Médicas</i>	40
<i>Desafíos para su Implementación en Entornos Clínicos</i>	41
<i>Relevancia del Software Open Source para la Corrección de Artefactos en</i>	
<i>Radiografía Digital</i>	42
Marco Metodológico	44
Tipo y Diseño de la Investigación	44
Enfoque de Investigación	45
Población y Unidad de Análisis.....	45
Criterios de Selección Documental	46
Fuentes y Técnicas de Recolección de Información	46
Técnicas de Análisis de la Información.....	47
Procedimiento Metodológico	48
Resultados	49
Caracterización de Artefactos y Herramientas	49
<i>Frecuencia e Impacto</i>	49
Inventario de Software.....	51
Desempeño Técnico	53
<i>Comparativa de Eficacia</i>	53
Análisis Por Tipo de Artefacto	56
Factores de Aplicabilidad Clínica.....	59

<i>Costo y Accesibilidad</i>	59
Desafíos Técnicos.....	60
Recomendaciones para la implementación clínica.....	63
Limitaciones y Perspectivas Futuras	63
Conclusiones	65
Referencias Bibliográficas	68

Lista de Tablas

Tabla 1 <i>Caracterización de los Principales Artefactos en Radiografía Digital Reportados en la Literatura Científica.....</i>	50
Tabla 2 <i>Herramientas Open Source Utilizadas para la Detección y Corrección de Artefactos en Imágenes Médicas</i>	52
Tabla 3 <i>Comparación del Desempeño Reportado Entre Métodos Manuales, Soluciones Open Source Basadas en Inteligencia Artificial y Software Propietario</i>	54
Tabla 4 <i>Técnicas de Detección y Corrección de Artefactos Según el Tipo de Alteración Radiológica</i>	57
Tabla 5 <i>Factores que Influyen en la Aplicabilidad Clínica de Herramientas Open Source para la Detección y Corrección de Artefactos en Imágenes Radiológicas</i>	61

Introducción

La evolución de las tecnologías de imagen médica ha transformado significativamente los procesos diagnósticos en los servicios de salud, permitiendo obtener representaciones anatómicas con mayores niveles de precisión, rapidez y disponibilidad para la toma de decisiones clínicas (Seeram, 2023). Dentro de este contexto, la radiografía digital ocupa un lugar relevante debido a su amplia utilización en diferentes especialidades médicas y a las ventajas que ofrece en términos de almacenamiento, transmisión y procesamiento de información diagnóstica (Bushberg et al., 2012).

A pesar de estos avances tecnológicos, la calidad de las imágenes radiológicas continúa enfrentando desafíos asociados a la presencia de artefactos, entendidos como alteraciones visuales que no corresponden a las estructuras anatómicas reales examinadas. Su aparición puede comprometer la interpretación clínica al generar distorsiones, ocultar hallazgos de interés o inducir errores diagnósticos que afectan la precisión del estudio (Selles et al., 2024). Estas alteraciones pueden originarse por múltiples factores relacionados con los sistemas de adquisición, las condiciones de exposición, el procesamiento digital de la imagen o incluso características propias del paciente y del entorno clínico (Inkinen et al., 2024).

La creciente complejidad de los sistemas de imagen médica ha impulsado el desarrollo de estrategias computacionales orientadas a fortalecer los procesos de control de calidad. En este escenario, el procesamiento digital de imágenes y las técnicas de inteligencia artificial han demostrado una capacidad cada vez mayor para identificar patrones complejos, automatizar tareas de análisis y mejorar la consistencia de los resultados obtenidos (Elhanashi et al., 2025). Diversas investigaciones han evidenciado que los algoritmos basados en aprendizaje profundo pueden detectar y clasificar artefactos con altos niveles de precisión, favoreciendo la

optimización de los flujos de trabajo y contribuyendo al fortalecimiento de la calidad diagnóstica (Ahmad et al., 2021; Cancian et al., 2025).

Paralelamente, el movimiento de software de código abierto ha adquirido una importancia creciente dentro del ámbito científico y tecnológico. La disponibilidad de herramientas open source no solo facilita el acceso a soluciones avanzadas para el análisis de imágenes médicas, sino que también promueve la transparencia metodológica, la reproducibilidad de los resultados y la posibilidad de adaptar las aplicaciones a diferentes necesidades institucionales (Fortunato & Galassi, 2021). Estas características adquieren especial relevancia en contextos donde las limitaciones presupuestales pueden restringir la adquisición de plataformas comerciales especializadas (Yılmaz, 2024).

En consideración a este panorama, la presente investigación se orienta al análisis de herramientas de software open source destinadas a la detección y corrección de artefactos en imágenes de radiografía digital. Mediante una revisión documental de literatura científica reciente, se examinan los enfoques tecnológicos utilizados, los indicadores de desempeño reportados y las posibilidades de implementación clínica descritas en estudios especializados. De esta manera, se busca aportar una visión crítica y actualizada sobre el potencial de estas herramientas como alternativas para fortalecer los procesos de aseguramiento de la calidad en el diagnóstico por imagen y favorecer el desarrollo de soluciones accesibles dentro del ámbito de la radiología digital.

Planteamiento del Problema

La transformación digital de los servicios de diagnóstico por imagen ha permitido mejorar significativamente los procesos de adquisición, almacenamiento y análisis de estudios radiológicos. Gracias a estos avances, la radiografía digital se ha consolidado como una de las herramientas más utilizadas en la práctica clínica. Sin embargo, la obtención de imágenes con calidad diagnóstica óptima continúa representando un desafío debido a la presencia de artefactos que pueden alterar la representación real de las estructuras anatómicas.

Según Kumari et al. (2024), los artefactos constituyen una de las principales limitaciones técnicas en las imágenes médicas, ya que pueden generar distorsiones que afectan la visualización de los tejidos y comprometen la precisión diagnóstica. Estas alteraciones pueden originarse por diferentes causas, entre ellas movimientos involuntarios del paciente, presencia de materiales metálicos, errores durante la adquisición de la imagen o limitaciones asociadas a los sistemas de procesamiento digital. Asimismo, Soltani et al. (2024) destacan que la presencia de artefactos puede dificultar la detección de hallazgos clínicamente relevantes y afectar la interpretación realizada por los profesionales de la salud.

De acuerdo con Wajer et al. (2024), los artefactos no solo impactan la calidad de la imagen, sino que también pueden incrementar la necesidad de repetir procedimientos diagnósticos, generando mayores costos operativos y una exposición adicional del paciente a radiación ionizante. Esta situación ha motivado la búsqueda de estrategias que permitan optimizar los procesos de control de calidad y reducir la influencia de estas alteraciones en la práctica clínica.

Tradicionalmente, la identificación de artefactos ha dependido de la evaluación visual realizada por médicos radiólogos y tecnólogos en imágenes diagnósticas. No obstante, Inkinen et al. (2024) señalan que el creciente volumen de estudios radiológicos y la variabilidad

inherente al análisis humano pueden afectar la eficiencia y consistencia de estos procesos. Como consecuencia, ha surgido un interés cada vez mayor por el desarrollo de herramientas automatizadas capaces de apoyar la detección temprana de errores y mejorar la calidad de las imágenes médicas.

En este contexto, Ahmad et al. (2021) demostraron que los modelos basados en aprendizaje profundo pueden identificar artefactos de manera automática con altos niveles de precisión. De forma similar, Wang et al. (2021) evidenciaron el potencial de las redes neuronales para reducir artefactos metálicos y mejorar la calidad visual de las imágenes obtenidas mediante técnicas radiológicas avanzadas. Más recientemente, Elhanashi et al. (2025) destacaron que la inteligencia artificial se ha convertido en una de las tecnologías con mayor proyección para fortalecer los sistemas de apoyo al diagnóstico médico mediante la automatización de tareas complejas de análisis de imágenes.

A pesar de estos avances, una proporción considerable de las soluciones desarrolladas se encuentra asociada a plataformas comerciales que requieren licencias especializadas y recursos económicos significativos para su implementación. Frente a esta realidad, Fortunato y Galassi (2021) argumentan que el software de código abierto favorece la transparencia científica, la reproducibilidad de los resultados y la democratización del conocimiento tecnológico. En la misma línea, Chen y Zhou (2025) destacan que los entornos open source promueven la innovación colaborativa y facilitan la adaptación de las herramientas a necesidades específicas de investigación y práctica profesional. Asimismo, Yılmaz (2024) resalta las ventajas económicas y operativas que estas soluciones pueden ofrecer en instituciones con recursos limitados.

Sin embargo, aunque existe un creciente interés por el uso de software open source en el procesamiento de imágenes médicas, la evidencia relacionada con su desempeño específico

en la detección y corrección de artefactos en radiografía digital aún se encuentra dispersa. Esto dificulta establecer con claridad cuáles son las herramientas más prometedoras, sus alcances reales y su potencial aplicación en escenarios clínicos. En consecuencia, surge la necesidad de analizar la literatura científica disponible con el fin de evaluar los prototipos de software open source desarrollados para este propósito y determinar su contribución al mejoramiento de la calidad diagnóstica en radiología digital. Por lo tanto, nos surge la siguiente pregunta ¿Cuál es el desempeño de los prototipos de software open source en la detección y corrección de artefactos en imágenes de radiografía digital?

Justificación

La producción de imágenes diagnósticas con niveles adecuados de calidad constituye uno de los pilares fundamentales de la radiología moderna, ya que la confiabilidad de la información obtenida influye directamente en la valoración clínica realizada por los profesionales de la salud. No obstante, la aparición de artefactos continúa representando una situación que puede afectar la fidelidad de las imágenes y generar dificultades durante el proceso de interpretación. Diversas investigaciones han señalado que estas alteraciones pueden modificar la apariencia de las estructuras anatómicas, reducir la calidad visual de los estudios e incluso interferir en la identificación de hallazgos relevantes para el diagnóstico (Kumari et al., 2024; Wajer et al., 2024).

En respuesta a esta problemática, durante los últimos años se ha observado un creciente interés por incorporar herramientas computacionales capaces de automatizar tareas relacionadas con el control de calidad de las imágenes médicas. Según Ahmad et al. (2021), los modelos basados en aprendizaje profundo han demostrado capacidad para reconocer patrones asociados a defectos presentes en las imágenes, mientras que Wang et al. (2021) reportan resultados favorables en la reducción de artefactos mediante arquitecturas avanzadas de redes neuronales. Estos avances reflejan el potencial que posee la inteligencia artificial para apoyar procesos tradicionalmente dependientes de la evaluación humana.

A pesar del desarrollo alcanzado en este campo, gran parte de las soluciones tecnológicas disponibles han sido diseñadas dentro de entornos comerciales cuyos costos de implementación, mantenimiento o licenciamiento pueden limitar su adopción en determinados contextos. Frente a esta realidad, el software de código abierto ha comenzado a ocupar un lugar relevante dentro de la investigación científica y el desarrollo tecnológico. Fortunato y Galassi (2021) sostienen que este modelo favorece la transparencia y la reproducibilidad de

los procesos de investigación, mientras que Chen y Zhou (2025) destacan que la colaboración abierta entre desarrolladores e investigadores impulsa la innovación y acelera la evolución de nuevas soluciones tecnológicas.

La pertinencia de esta investigación radica en la necesidad de examinar de manera organizada la evidencia científica relacionada con prototipos open source orientados a la detección y corrección de artefactos en imágenes de radiografía digital. Aunque existe una producción creciente de estudios sobre inteligencia artificial aplicada al análisis de imágenes médicas, la información referente al rendimiento, alcance y aplicabilidad de estas herramientas continúa distribuida en múltiples publicaciones, lo que dificulta establecer una visión global sobre sus capacidades y limitaciones.

Asimismo, el estudio adquiere relevancia desde una perspectiva académica y profesional, ya que permitirá identificar los principales enfoques metodológicos empleados en el desarrollo de estas tecnologías, las métricas utilizadas para evaluar su desempeño y los resultados obtenidos en diferentes escenarios de investigación. Esta información puede convertirse en un recurso de consulta para estudiantes, docentes, investigadores y profesionales interesados en las aplicaciones de la inteligencia artificial dentro del ámbito de la radiología digital.

Por otra parte, Yılmaz (2024) señala que las soluciones de código abierto pueden representar una alternativa estratégica para organizaciones que buscan fortalecer sus capacidades tecnológicas sin depender exclusivamente de plataformas propietarias. En este sentido, analizar el potencial de estas herramientas resulta pertinente no solo desde el punto de vista científico, sino también en términos de accesibilidad, sostenibilidad e innovación tecnológica aplicada al sector salud.

En consecuencia, la presente investigación se justifica por su contribución al análisis crítico de los prototipos de software open source desarrollados para la corrección de artefactos en radiografía digital, aportando una síntesis actualizada del conocimiento disponible y generando insumos que puedan orientar futuras investigaciones y procesos de adopción tecnológica en el campo de las imágenes diagnósticas.

Objetivos

Objetivo General

Analizar el desempeño de herramientas de software open source orientadas a la detección y corrección automática de artefactos en imágenes de radiografía digital, a partir de la evidencia científica reportada en la literatura especializada.

Objetivos Específicos

Caracterizar los tipos de artefactos más frecuentes en radiografía digital y su impacto sobre la calidad de la imagen y la interpretación clínica.

Identificar las principales herramientas de software open source utilizadas para la detección y corrección de artefactos en imágenes médicas, así como los enfoques técnicos empleados en su desarrollo.

Comparar el rendimiento de las herramientas open source frente a métodos manuales y sistemas propietarios, considerando las métricas de evaluación reportadas en la literatura científica.

Evaluar las ventajas, limitaciones y aplicabilidad clínica de las herramientas open source en los procesos de diagnóstico por imágenes.

Marco Teórico

Artefactos en Imágenes de Radiografía Digital

La calidad de una imagen radiológica depende de múltiples factores relacionados con la adquisición, procesamiento y visualización de la información diagnóstica (Bushberg et al., 2011; Seeram, 2019). Aun cuando los sistemas digitales han permitido importantes avances en términos de resolución, almacenamiento y transmisión de imágenes, continúan presentándose alteraciones que pueden afectar la representación fiel de las estructuras anatómicas examinadas (Kahn, 2014). Estas alteraciones son conocidas como artefactos radiológicos y constituyen uno de los principales desafíos en los procesos de control de calidad de las imágenes médicas (Seeram, 2019).

De acuerdo con Kumari et al. (2024), un artefacto puede definirse como cualquier anomalía o distorsión presente en una imagen médica que no corresponde a las características reales del paciente. Estas alteraciones pueden surgir durante diferentes etapas del proceso radiológico, incluyendo la adquisición de la imagen, la reconstrucción computacional, el procesamiento digital o incluso la visualización final del estudio. Como consecuencia, los artefactos pueden modificar la apariencia de tejidos y órganos, dificultando la interpretación clínica y reduciendo la confiabilidad diagnóstica (Soltani et al., 2024).

Origen y Clasificación de los Artefactos

Los artefactos radiológicos pueden clasificarse según la causa que los genera, incluyendo factores relacionados con el paciente, el sistema de adquisición, los detectores digitales y los procesos de reconstrucción y procesamiento de imágenes (Bushberg et al., 2011; Seeram, 2019). Una de las categorías más frecuentes corresponde a los artefactos asociados al movimiento del paciente durante la exposición radiográfica. Cuando se producen desplazamientos involuntarios, las estructuras anatómicas pueden aparecer borrosas o

deformadas, dificultando la evaluación adecuada de los hallazgos clínicos (Bushberg et al., 2011; Inkinen et al., 2024).

Otra categoría importante corresponde a los artefactos relacionados con el sistema de adquisición de imágenes. Estos pueden originarse por defectos en los detectores digitales, errores de calibración, fallas electrónicas o problemas durante la transferencia de datos. Según Inkinen et al. (2024), este tipo de alteraciones puede afectar significativamente los procesos de aseguramiento de la calidad en los servicios de diagnóstico por imagen.

Los artefactos metálicos representan una de las formas más complejas de distorsión en imágenes médicas. La presencia de prótesis, implantes dentales, dispositivos ortopédicos u otros elementos metálicos produce una atenuación irregular de los rayos X, generando líneas brillantes, sombras o regiones de pérdida de información que afectan la visualización de estructuras adyacentes. Diversos estudios han señalado que este tipo de artefacto constituye una de las principales áreas de investigación dentro del procesamiento de imágenes médicas debido a su impacto sobre la precisión diagnóstica (Kumari et al., 2024; Wajer et al., 2024).

Asimismo, pueden presentarse artefactos asociados al ruido digital, caracterizados por la aparición de variaciones aleatorias en los niveles de intensidad de la imagen afectando la calidad visual del estudio y dificultando la identificación de detalles anatómicos relevantes (Bushberg et al., 2011; Seeram, 2019). Estas alteraciones suelen estar relacionadas con bajas dosis de radiación, limitaciones técnicas de los detectores o condiciones específicas de adquisición, afectando la calidad visual del estudio y dificultando la identificación de detalles anatómicos relevantes.

Impacto de los Artefactos sobre la Calidad Diagnóstica

La importancia de los artefactos trasciende el ámbito técnico debido a sus posibles repercusiones clínicas, ya que pueden afectar la visualización de estructuras anatómicas,

alterar la interpretación diagnóstica y comprometer la toma de decisiones médicas (Soltani et al., 2024; Wajer et al., 2024). Una imagen afectada por distorsiones significativas puede conducir a interpretaciones incorrectas, aumentar la incertidumbre diagnóstica o incluso ocultar hallazgos patológicos relevantes. En determinadas circunstancias, estas alteraciones pueden generar resultados falsamente positivos o falsamente negativos, afectando la toma de decisiones médicas y la planificación terapéutica.

Soltani et al. (2024) señalan que la presencia de artefactos puede influir directamente en la capacidad del profesional para identificar estructuras anatómicas específicas y valorar adecuadamente determinadas condiciones clínicas. De manera similar, investigaciones recientes han evidenciado que los artefactos metálicos continúan representando una limitación importante para diversas modalidades de imagen médica, especialmente cuando se requiere una alta precisión diagnóstica (Wajer et al., 2024).

Además del impacto clínico, los artefactos pueden generar consecuencias operativas y económicas para las instituciones de salud, debido a la necesidad de repetir estudios, aumentar los tiempos de procesamiento y destinar recursos adicionales a las actividades de aseguramiento de la calidad (Bushberg et al., 2011; Seeram, 2019). Cuando la calidad de una imagen radiológica resulta insuficiente para su adecuada interpretación diagnóstica, puede ser necesario repetir el procedimiento, lo que incrementa los costos operativos y expone al paciente a dosis adicionales de radiación ionizante. Esta situación ha impulsado el fortalecimiento de los programas de control de calidad en radiología digital, orientados a garantizar la adquisición de imágenes con calidad diagnóstica adecuada desde la primera exposición y a reducir errores asociados tanto a los equipos como a los procesos de adquisición y procesamiento de imágenes (Bushberg et al., 2011; Seeram, 2019). Asimismo, los sistemas de gestión y almacenamiento de imágenes médicas requieren mecanismos de

aseguramiento de la calidad que permitan mantener la confiabilidad diagnóstica y la eficiencia de los flujos de trabajo clínicos (Kahn, 2014).

Necesidad de Estrategias para Corrección y Detección de Artefactos

La creciente complejidad de los sistemas de imagen digital ha impulsado el desarrollo de métodos cada vez más sofisticados para la identificación y reducción de artefactos, incorporando herramientas de procesamiento digital de imágenes, aprendizaje automático e inteligencia artificial para fortalecer los procesos de control de calidad (Elhanashi et al., 2025; Hosny et al., 2018). Tradicionalmente, estas tareas dependían principalmente de la evaluación visual realizada por especialistas; sin embargo, el incremento en el volumen de estudios radiológicos y la necesidad de optimizar los tiempos de análisis han favorecido la incorporación de herramientas automatizadas basadas en procesamiento digital de imágenes e inteligencia artificial (Inkinen et al., 2024).

En este contexto, la detección temprana y la corrección eficiente de artefactos se han convertido en objetivos prioritarios dentro de la investigación en radiología digital. El desarrollo de algoritmos capaces de identificar automáticamente estas alteraciones representa una oportunidad para fortalecer los procesos de control de calidad, mejorar la confiabilidad diagnóstica y reducir las limitaciones asociadas a la evaluación exclusivamente manual. Por esta razón, las tecnologías orientadas al análisis automatizado de imágenes constituyen actualmente una de las áreas de mayor crecimiento dentro del campo de la imagenología médica (Ahmad et al., 2021; Elhanashi et al., 2025).

Métodos para la Detección y Corrección de Artefactos

La presencia de artefactos en las imágenes radiológicas ha impulsado el desarrollo de diferentes estrategias orientadas a su identificación y reducción. A lo largo del tiempo, los procedimientos utilizados para abordar estas alteraciones han evolucionado desde métodos

basados exclusivamente en la observación humana hasta sistemas automatizados sustentados en algoritmos avanzados de procesamiento digital de imágenes. Esta evolución responde a la necesidad de garantizar una mayor precisión en los procesos de control de calidad y optimizar la confiabilidad de los estudios diagnósticos (Doi, 2007).

La detección y corrección de artefactos constituyen etapas fundamentales dentro de los programas de aseguramiento de la calidad en radiología digital. Su adecuada implementación permite minimizar errores de interpretación, mejorar la visualización anatómica y reducir la necesidad de repetir procedimientos diagnósticos. En los sistemas modernos de radiología digital, estas actividades forman parte de los procesos rutinarios de control de calidad destinados a garantizar la obtención de imágenes diagnósticas confiables (Seeram, 2019).

Métodos Manuales para la Detección de Artefactos

Antes de la incorporación de herramientas computacionales avanzadas, la identificación de artefactos dependía principalmente de la evaluación realizada por radiólogos, médicos especialistas y tecnólogos en imágenes diagnósticas. Este proceso consiste en la revisión visual de las imágenes obtenidas con el propósito de identificar alteraciones que puedan afectar la calidad diagnóstica o interferir con la correcta interpretación de las estructuras anatómicas (Bushberg et al., 2011).

La detección manual se fundamenta en el conocimiento técnico y la experiencia clínica del profesional, quien debe diferenciar entre hallazgos anatómicos reales y alteraciones generadas durante la adquisición o procesamiento de la imagen. Según Inkinen et al. (2024), este tipo de evaluación, continúa siendo un componente esencial dentro de los programas de control de calidad, especialmente cuando se requiere validar resultados obtenidos mediante sistemas automatizados.

Una de las principales ventajas de los métodos manuales radica en la capacidad del especialista para contextualizar los hallazgos dentro del escenario clínico del paciente. No obstante, este procedimiento suele requerir más tiempo y puede resultar menos consistente cuando se manejan grandes volúmenes de imágenes, situación que ha motivado el desarrollo de herramientas automatizadas para apoyar los procesos de evaluación y control de calidad (Mun et al., 2021).

No obstante, diversos autores han señalado limitaciones asociadas a este enfoque. La evaluación visual puede verse influenciada por factores subjetivos relacionados con la experiencia del observador, la carga laboral o las condiciones de interpretación de las imágenes. Asimismo, el incremento constante en el volumen de estudios radiológicos ha generado nuevos desafíos para los servicios de diagnóstico por imagen, donde la revisión individual de cada examen puede demandar una cantidad considerable de tiempo y recursos humanos (Inkinen et al., 2024).

Estas limitaciones han impulsado la búsqueda de soluciones tecnológicas capaces de complementar el trabajo de los especialistas, permitiendo mejorar la eficiencia de los procesos de control de calidad sin sustituir el criterio clínico profesional.

Métodos Automatizados para la Detección de Artefactos

El avance de la informática médica y del procesamiento digital de imágenes ha favorecido el desarrollo de métodos automatizados orientados a la detección y corrección de artefactos, sustentados en técnicas de aprendizaje automático y aprendizaje profundo que permiten analizar grandes volúmenes de datos de manera eficiente (Goodfellow et al., 2016; LeCun et al., 2015; Shen et al., 2017). A diferencia de los procedimientos manuales, estos sistemas utilizan algoritmos computacionales para analizar las características de las imágenes y reconocer patrones asociados a posibles alteraciones técnicas.

Los primeros enfoques automatizados se basaron en técnicas clásicas de procesamiento digital de imágenes, incluyendo filtros matemáticos, análisis de histogramas, detección de bordes y métodos estadísticos para identificar anomalías en la distribución de los niveles de intensidad (González & Woods, 2018; Bovik, 2013).

Posteriormente, el incremento en la capacidad computacional y la disponibilidad de grandes bases de datos impulsaron la incorporación de técnicas más sofisticadas basadas en aprendizaje automático. De acuerdo con Ahmad et al. (2021), los sistemas automatizados pueden entrenarse para reconocer diferentes tipos de artefactos mediante el análisis de miles de imágenes previamente clasificadas, alcanzando niveles de precisión cada vez más elevados.

Los avances más recientes han estado asociados a la aplicación de modelos de aprendizaje profundo capaces de identificar características complejas que resultan difíciles de detectar mediante métodos convencionales. Estas herramientas han demostrado resultados prometedores en la detección automática de artefactos de movimiento, ruido, distorsiones geométricas y artefactos metálicos presentes en diversas modalidades de imagen médica (Ahmad et al., 2021).

Además de detectar alteraciones, algunos sistemas actuales son capaces de estimar su nivel de severidad y priorizar aquellas imágenes que requieren revisión especializada. Cancian et al. (2025) reportan que este tipo de enfoques contribuye a optimizar los procesos de control de calidad al facilitar la clasificación automática de estudios según el impacto que los artefactos generan sobre la calidad diagnóstica.

La incorporación de métodos automatizados no pretende reemplazar la intervención del especialista, sino fortalecer los procesos de análisis mediante herramientas que aporten rapidez, consistencia y capacidad de procesamiento frente al creciente volumen de información generado en los servicios de radiología. En consecuencia, estos avances han

establecido las bases para el desarrollo de sistemas más complejos sustentados en inteligencia artificial, los cuales actualmente representan una de las áreas de mayor crecimiento dentro del procesamiento de imágenes médicas y del diagnóstico asistido por computadora (Hosny et al., 2018; Mun et al., 2021; Elhanashi et al., 2025).

Inteligencia Artificial y Aprendizaje Profundo en Radiología

El crecimiento de los sistemas digitales de imagen médica ha generado una cantidad cada vez mayor de información radiológica que requiere ser procesada, analizada e interpretada de manera eficiente. Ante esta realidad, la inteligencia artificial (IA) ha adquirido un papel relevante dentro de la radiología moderna, al proporcionar herramientas capaces de apoyar tareas relacionadas con la detección de anomalías, la clasificación de imágenes, la segmentación anatómica y el control de calidad de los estudios diagnósticos (Mun et al., 2021).

La inteligencia artificial puede definirse como el conjunto de métodos computacionales diseñados para simular determinadas capacidades cognitivas humanas mediante el aprendizaje a partir de datos (Goodfellow et al., 2016). En el ámbito radiológico, estas tecnologías permiten desarrollar sistemas capaces de identificar patrones complejos presentes en las imágenes médicas y generar resultados útiles para apoyar los procesos diagnósticos (Hosny et al., 2018). Según Elhanashi et al. (2025), la incorporación de modelos de inteligencia artificial en radiología ha experimentado un crecimiento acelerado debido a los avances en capacidad computacional, disponibilidad de bases de datos médicas y desarrollo de nuevos algoritmos de análisis de imágenes.

El interés por estas tecnologías se relaciona con la necesidad de optimizar la interpretación de grandes volúmenes de información diagnóstica. Diversas investigaciones han demostrado que los sistemas de inteligencia artificial pueden contribuir a mejorar la eficiencia

de determinados procesos clínicos, especialmente aquellos asociados con tareas repetitivas de identificación, clasificación y evaluación de imágenes médicas (Lawrence et al., 2025).

Aprendizaje Automático y Aprendizaje Profundo

Dentro de la inteligencia artificial, uno de los campos con mayor aplicación en radiología corresponde al aprendizaje automático o machine learning. Este enfoque permite que los sistemas computacionales aprendan a reconocer patrones mediante el análisis de datos previamente procesados, sin necesidad de que todas las reglas sean programadas explícitamente por un desarrollador (Goodfellow et al., 2016).

El aprendizaje automático utiliza algoritmos capaces de construir modelos predictivos a partir de ejemplos previamente etiquetados. En imágenes médicas, estos modelos pueden entrenarse para identificar características asociadas a tejidos normales, alteraciones patológicas o defectos técnicos presentes durante la adquisición de la imagen. Gracias a este proceso de entrenamiento, los algoritmos adquieren la capacidad de realizar predicciones sobre nuevas imágenes que no habían sido analizadas previamente (Hosny et al., 2018)..

Una evolución de este enfoque corresponde al aprendizaje profundo o deep learning, considerado actualmente una de las tecnologías más influyentes dentro del análisis automatizado de imágenes médicas (LeCun et al., 2015; Goodfellow et al., 2016; Shen et al., 2017). Según Elhanashi et al. (2025), el aprendizaje profundo utiliza redes neuronales artificiales compuestas por múltiples capas de procesamiento que permiten extraer automáticamente características complejas presentes en grandes volúmenes de datos.

La principal ventaja del aprendizaje profundo radica en su capacidad para identificar relaciones complejas que podrían pasar desapercibidas mediante métodos convencionales de análisis. Esto ha favorecido su aplicación en tareas relacionadas con clasificación de imágenes,

segmentación anatómica, detección de lesiones, evaluación de calidad y reconocimiento automático de artefactos radiológicos.

Redes Neuronales Convolucionales para el Análisis de Imágenes Médicas

Entre las arquitecturas de aprendizaje profundo más utilizadas en radiología se encuentran las Redes Neuronales Convolucionales (CNN), diseñadas específicamente para el procesamiento de información visual y ampliamente utilizadas en clasificación, segmentación y detección de patrones en imágenes médicas (Litjens et al., 2017).

Las CNN funcionan mediante una serie de capas que analizan progresivamente diferentes características de una imagen, desde elementos básicos como bordes y contornos hasta patrones anatómicos más complejos. Este mecanismo permite que el sistema aprenda automáticamente qué regiones contienen información relevante para la tarea que se desea realizar (Goodfellow et al., 2016).

De acuerdo con Elhanashi et al. (2025), las redes convolucionales han alcanzado resultados sobresalientes en múltiples aplicaciones radiológicas debido a su capacidad para procesar grandes cantidades de imágenes y detectar patrones con elevados niveles de precisión. Como consecuencia, estas arquitecturas se han convertido en la base de numerosos sistemas desarrollados para apoyar el diagnóstico médico y los procesos de aseguramiento de la calidad.

Además de la clasificación de imágenes, las CNN han sido utilizadas para segmentar órganos, identificar lesiones, detectar anomalías técnicas y mejorar la calidad visual de estudios afectados por diferentes tipos de artefactos. Su versatilidad ha impulsado una amplia producción científica orientada al desarrollo de nuevas aplicaciones dentro de la imagenología médica (van Ginneken, 2017).

Aplicaciones de la Inteligencia Artificial en la Detección y Corrección de Artefactos

Una de las aplicaciones más prometedoras de la inteligencia artificial en radiología corresponde a la detección y corrección automática de artefactos. El objetivo principal de estos sistemas consiste en identificar alteraciones que puedan afectar la calidad diagnóstica de las imágenes y aplicar procedimientos que reduzcan su impacto sobre la visualización anatómica (Wismueller et al., 2022).

Ahmad et al. (2021) desarrollaron modelos basados en aprendizaje profundo capaces de detectar artefactos presentes en imágenes médicas mediante el análisis automatizado de características visuales complejas. Los resultados obtenidos demostraron que estos sistemas pueden alcanzar niveles de desempeño comparables a los observados en procesos de evaluación manual realizados por especialistas.

Por otra parte, investigaciones recientes han ampliado las capacidades de estos algoritmos al incorporar mecanismos que permiten clasificar el grado de severidad de los artefactos detectados. Según Cancian et al. (2025), esta funcionalidad facilita la priorización de estudios que requieren revisión especializada y fortalece los procedimientos de control de calidad dentro de los servicios de diagnóstico por imagen.

En relación con la corrección automática, Wang et al. (2021) evidenciaron que las redes neuronales profundas pueden reducir significativamente la presencia de artefactos metálicos mediante el aprendizaje de patrones asociados a dichas distorsiones. De manera complementaria, Wajer et al. (2024) destacan que las técnicas basadas en inteligencia artificial han demostrado capacidad para mejorar la calidad visual de las imágenes preservando información anatómica relevante para el diagnóstico clínico.

Estos avances han convertido a la inteligencia artificial en uno de los principales motores de innovación dentro de la radiología digital. Su capacidad para automatizar procesos

complejos, mejorar la calidad de imagen y apoyar la toma de decisiones clínicas ha favorecido el desarrollo de nuevas herramientas computacionales, muchas de las cuales se implementan actualmente mediante plataformas y entornos de software open source orientados a la investigación y al desarrollo tecnológico (Fortunato & Galassi, 2021).

Evaluación de Prototipos de Software para Análisis de Imágenes Médicas

El desarrollo de herramientas computacionales aplicadas al análisis de imágenes médicas ha experimentado un crecimiento significativo durante las últimas décadas. Este avance ha favorecido la creación de prototipos de software capaces de automatizar tareas relacionadas con la detección de anomalías, la clasificación de imágenes, la segmentación anatómica y la evaluación de la calidad diagnóstica. En este contexto, la validación de dichas herramientas constituye una etapa fundamental, ya que permite determinar su desempeño, confiabilidad y potencial aplicabilidad en escenarios clínicos reales.

Un prototipo de software puede entenderse como una versión funcional de una herramienta informática desarrollada con el propósito de evaluar conceptos, algoritmos o metodologías antes de su implementación definitiva. En el ámbito biomédico, estos prototipos suelen utilizarse para comprobar la viabilidad de nuevas tecnologías orientadas al procesamiento de imágenes médicas, permitiendo identificar fortalezas, limitaciones y oportunidades de mejora antes de su incorporación a entornos asistenciales.

La evaluación de estos sistemas resulta especialmente importante debido a que las decisiones clínicas dependen, en gran medida, de la calidad y precisión de la información proporcionada por las imágenes diagnósticas. Por esta razón, los estudios científicos suelen emplear diferentes indicadores que permiten medir objetivamente la capacidad de los algoritmos para detectar, clasificar o corregir alteraciones presentes en las imágenes médicas (Ahmad et al., 2021; Inkinen et al., 2024).

Métricas para la Evaluación del Desempeño

La valoración objetiva de un prototipo de software requiere la utilización de métricas que permitan cuantificar su rendimiento frente a un conjunto de datos previamente conocidos. Estas métricas facilitan la comparación entre diferentes algoritmos y proporcionan evidencia sobre su capacidad para resolver el problema para el cual fueron diseñados. En el ámbito de la inteligencia artificial aplicada a imágenes médicas, la evaluación cuantitativa constituye una etapa fundamental para determinar la confiabilidad y utilidad clínica de los modelos desarrollados (Hosny et al., 2018).

Entre los indicadores más utilizados se encuentra la exactitud o accuracy, la cual expresa la proporción de predicciones correctas realizadas por un modelo respecto al total de casos evaluados. Aunque esta métrica proporciona una visión general del rendimiento, suele complementarse con otros indicadores que ofrecen una evaluación más detallada del comportamiento del sistema, especialmente cuando existen conjuntos de datos desbalanceados (Goodfellow et al., 2016).

La sensibilidad representa la capacidad del algoritmo para identificar correctamente los casos positivos, mientras que la especificidad mide su habilidad para reconocer adecuadamente los casos negativos. Ambos parámetros son ampliamente utilizados en estudios relacionados con diagnóstico médico, ya que permiten evaluar el equilibrio entre detección efectiva y reducción de errores de clasificación (Ridhi et al., 2024).

Otra métrica frecuentemente reportada corresponde a la precisión o precision, la cual indica la proporción de resultados positivos que realmente pertenecen a la categoría evaluada. De manera complementaria, el F1-Score combina precisión y sensibilidad en un único indicador, proporcionando una medida equilibrada del desempeño cuando existen diferencias significativas entre las clases analizadas. Estas métricas son ampliamente utilizadas en

sistemas de aprendizaje automático y aprendizaje profundo orientados al análisis de imágenes médicas (LeCun et al., 2015).

Asimismo, diversos estudios emplean la curva ROC (Receiver Operating Characteristic) y el área bajo la curva (Area Under the Curve o AUC) para analizar la capacidad discriminativa de los algoritmos. Estos indicadores permiten valorar el comportamiento del modelo frente a diferentes umbrales de clasificación y constituyen herramientas ampliamente aceptadas para la evaluación de sistemas de inteligencia artificial aplicados al análisis de imágenes médicas (Elhanashi et al., 2025).

En aplicaciones radiológicas, el uso combinado de estas métricas permite realizar una valoración más completa del desempeño de los algoritmos, facilitando la comparación entre diferentes modelos y contribuyendo a la selección de soluciones con mayor potencial de implementación clínica. La adecuada interpretación de estos indicadores resulta esencial para garantizar que los sistemas de inteligencia artificial mantengan niveles adecuados de precisión, confiabilidad y seguridad en entornos reales de atención en salud (Lawrence et al., 2025).

Indicadores Utilizados en la Detección y Corrección de Artefactos

La evaluación de herramientas destinadas a la detección y corrección de artefactos requiere indicadores específicos que permitan valorar tanto la capacidad de identificación de las alteraciones como la calidad de las imágenes obtenidas después del procesamiento. La selección adecuada de estas métricas resulta fundamental para determinar la eficacia de los algoritmos y su potencial aplicación en entornos clínicos reales (Hosny et al., 2018).

En los sistemas de detección automática, las métricas más empleadas corresponden a sensibilidad, especificidad, precisión, exactitud y F1-Score, ya que permiten determinar la eficacia del algoritmo para reconocer correctamente la presencia de artefactos. Ahmad et al.

(2021) reportaron el uso de estos indicadores para evaluar modelos de aprendizaje profundo destinados a la identificación automatizada de defectos presentes en imágenes médicas.

Por otra parte, los estudios enfocados en corrección de artefactos suelen incorporar métricas relacionadas con la calidad de imagen. Entre ellas destacan la Relación Señal-Ruido (Signal-to-Noise Ratio, SNR), la Relación Pico Señal-Ruido (Peak Signal-to-Noise Ratio, PSNR) y el Índice de Similitud Estructural (Structural Similarity Index, SSIM), las cuales permiten cuantificar el nivel de conservación de la información anatómica después de aplicar algoritmos de corrección (Wang et al., 2021).

La SNR constituye uno de los indicadores más utilizados para evaluar la calidad de las imágenes médicas, debido a que expresa la relación entre la señal útil y el ruido presente en la imagen. Por su parte, el PSNR permite comparar la imagen procesada con una imagen de referencia, mientras que el SSIM analiza la similitud estructural considerando aspectos relacionados con luminancia, contraste y estructura anatómica (González & Woods, 2018).

La utilización conjunta de estas métricas proporciona una evaluación más completa del desempeño de los prototipos de software, ya que considera tanto la capacidad de detectar alteraciones como la calidad final de las imágenes procesadas. Este enfoque integral es ampliamente recomendado en investigaciones relacionadas con inteligencia artificial aplicada a imágenes médicas, ya que permite valorar simultáneamente el rendimiento del algoritmo y la preservación de la información diagnóstica (Elhanashi et al., 2025).

Comparación entre Métodos Manuales y Automatizados

Uno de los principales objetivos de la evaluación de prototipos consiste en determinar en qué medida los sistemas automatizados pueden complementar o mejorar los procedimientos tradicionales realizados por especialistas. Esta comparación permite analizar aspectos

relacionados con precisión diagnóstica, velocidad de procesamiento, consistencia de los resultados y capacidad de adaptación a grandes volúmenes de información.

Los métodos manuales continúan siendo considerados el estándar de referencia en numerosos procesos de validación debido a la experiencia clínica de los profesionales que participan en la interpretación de las imágenes. Sin embargo, diversos estudios han señalado que los sistemas automatizados ofrecen ventajas importantes en términos de rapidez, reproducibilidad y capacidad de análisis masivo de datos (Inkinen et al., 2024).

Las investigaciones más recientes sugieren que los algoritmos basados en inteligencia artificial pueden alcanzar niveles de rendimiento comparables a los obtenidos mediante evaluación humana en determinadas tareas específicas de detección de artefactos y control de calidad de imágenes médicas (Cancian et al., 2025). No obstante, la mayoría de los autores coinciden en que estas herramientas deben concebirse como sistemas de apoyo que complementan la labor del especialista, más que como sustitutos de su criterio profesional.

En consecuencia, la evaluación rigurosa de prototipos de software constituye un elemento esencial para determinar la utilidad real de estas tecnologías dentro de la práctica radiológica. Los resultados obtenidos mediante diferentes métricas permiten identificar las herramientas con mayor potencial de aplicación clínica y establecer las bases para futuras investigaciones orientadas al perfeccionamiento de los sistemas de análisis automatizado de imágenes médicas.

Software Open Source en el Desarrollo de Herramientas para Radiología Digital

La transformación digital del sector salud ha impulsado el desarrollo de herramientas informáticas cada vez más especializadas para el procesamiento, análisis y gestión de imágenes médicas. Dentro de este contexto, el software open source o de código abierto ha adquirido una relevancia creciente debido a su capacidad para facilitar la innovación

tecnológica, promover la colaboración científica y ofrecer alternativas accesibles frente a las soluciones propietarias. Su adopción ha permitido que investigadores, desarrolladores e instituciones de salud participen activamente en la creación de tecnologías orientadas a mejorar los procesos diagnósticos y la calidad de la atención médica (Fortunato & Galassi, 2021).

De acuerdo con Fortunato y Galassi (2021), el software de código abierto constituye un modelo de desarrollo basado en la disponibilidad pública del código fuente, lo que permite que diferentes usuarios puedan examinarlo, modificarlo y adaptarlo a necesidades específicas. Esta característica favorece la transparencia tecnológica y contribuye a la reproducibilidad científica, aspectos especialmente importantes en áreas donde los resultados deben ser verificables y confiables, como ocurre en la investigación biomédica.

Por su parte, Chen y Zhou (2025) señalan que los ecosistemas colaborativos propios del movimiento open source han favorecido la aceleración de la innovación tecnológica, permitiendo que comunidades internacionales de desarrolladores participen en la creación y optimización de herramientas especializadas para distintos sectores, incluido el ámbito sanitario.

En radiología, el software open source ha facilitado el desarrollo de aplicaciones orientadas al procesamiento digital de imágenes, la automatización de tareas diagnósticas y la integración de algoritmos de inteligencia artificial. Según Bridge et al. (2021), la disponibilidad de bibliotecas abiertas y estándares interoperables ha contribuido a mejorar la gestión de anotaciones médicas y la integración de modelos de aprendizaje automático dentro de los flujos de trabajo radiológicos.

De manera complementaria, Kathiravelu et al. (2020) destacan que los entornos abiertos permiten construir pipelines de aprendizaje automático compatibles con imágenes

médicas en formato DICOM, favoreciendo el entrenamiento y la validación de modelos de inteligencia artificial sobre datos obtenidos en condiciones clínicas reales.

La interoperabilidad constituye otro aspecto fundamental para la implementación de estas herramientas. Pinykh (2012) señala que los estándares DICOM permiten garantizar el intercambio uniforme de imágenes médicas entre diferentes sistemas y dispositivos, mientras que Kahn (2014) resalta la importancia de los sistemas PACS como infraestructura esencial para el almacenamiento, recuperación y distribución de estudios radiológicos en entornos hospitalarios.

Asimismo, la integración de algoritmos de inteligencia artificial dentro de los sistemas de información radiológica ha comenzado a transformar los procesos clínicos tradicionales. Pérez-Sanpablo et al. (2025) indican que la incorporación de herramientas basadas en IA dentro de plataformas PACS puede contribuir a mejorar la eficiencia operativa, optimizar los flujos de trabajo y fortalecer la precisión diagnóstica.

La creciente incorporación de soluciones basadas en inteligencia artificial también ha impulsado la expansión del mercado de aplicaciones radiológicas. Antonissen et al. (2026) identificaron más de 170 productos comerciales de inteligencia artificial disponibles para radiología, evidenciando el rápido crecimiento de estas tecnologías y su progresiva integración en la práctica clínica.

Desde una perspectiva económica, el software open source representa una alternativa especialmente atractiva para instituciones con recursos limitados. Yılmaz (2024) destaca que la ausencia de costos asociados a licencias comerciales facilita el acceso a tecnologías avanzadas y favorece la sostenibilidad financiera de los proyectos tecnológicos a largo plazo.

No obstante, la adopción de estas herramientas también implica desafíos relacionados con la validación clínica, la seguridad de los datos, el mantenimiento de los sistemas y la

capacitación del personal. Aldhafeeri (2025) señala que la implementación de sistemas de inteligencia artificial en radiología requiere el cumplimiento de marcos regulatorios, éticos y legales que garanticen la seguridad del paciente y la confiabilidad de los resultados obtenidos. De manera complementaria, Dean et al. (2025) indican que la implementación exitosa de estas tecnologías demanda estrategias de monitoreo continuo que permitan verificar su desempeño bajo condiciones reales de práctica clínica.

En conjunto, la evidencia disponible sugiere que el software open source constituye una alternativa viable para el desarrollo de herramientas destinadas al análisis de imágenes médicas. Su combinación con tecnologías de inteligencia artificial, estándares de interoperabilidad y plataformas de gestión radiológica ha favorecido la creación de soluciones innovadoras que contribuyen al fortalecimiento de la calidad diagnóstica y al avance de la radiología digital (Mun et al., 2021).

Fundamentos del Software Open Source

El concepto de software open source se fundamenta en principios de acceso, colaboración, transparencia y mejora continua. A diferencia del software propietario, donde el código fuente permanece restringido y controlado por una empresa o desarrollador específico, las soluciones de código abierto permiten que usuarios, investigadores y desarrolladores accedan a su estructura interna, la modifiquen y contribuyan a su evolución tecnológica (Fortunato & Galassi, 2021).

Según Fortunato y Galassi (2021), este modelo favorece la construcción colectiva del conocimiento, ya que investigadores y profesionales pueden analizar el funcionamiento interno de los sistemas, identificar posibles limitaciones y proponer mejoras basadas en evidencia científica. Esta dinámica ha permitido la creación de herramientas robustas que

evolucionan constantemente gracias a las contribuciones realizadas por comunidades académicas y tecnológicas distribuidas en diferentes partes del mundo.

Por su parte, Chen y Zhou (2025) señalan que los ecosistemas colaborativos característicos del movimiento open source han contribuido significativamente a acelerar los procesos de innovación tecnológica, facilitando el intercambio de conocimientos y el desarrollo conjunto de soluciones especializadas para diferentes sectores productivos y científicos.

Desde una perspectiva científica, el acceso al código fuente también facilita la validación de algoritmos, la reproducibilidad de los resultados experimentales y la verificación independiente de los procedimientos implementados, aspectos considerados fundamentales dentro de la investigación académica y el desarrollo tecnológico (Fortunato & Galassi, 2021). Estas características favorecen la transparencia metodológica y fortalecen la confiabilidad de los resultados obtenidos.

Adicionalmente, el software open source representa una alternativa económicamente viable para instituciones que disponen de recursos limitados, debido a la ausencia de costos asociados a licencias comerciales y a la posibilidad de adaptar las herramientas a necesidades específicas de cada organización (Yılmaz, 2024). Por esta razón, el software de código abierto se ha convertido en una opción ampliamente utilizada en disciplinas relacionadas con la informática médica, la ingeniería biomédica y el análisis computacional de imágenes.

Ventajas del Software Open Source en Investigación y Salud

La utilización de software open source ofrece múltiples beneficios dentro de los entornos académicos y clínicos. Una de las ventajas más relevantes corresponde a la reducción de costos asociados al licenciamiento de software propietario. Esta característica resulta

especialmente importante para instituciones educativas, centros de investigación y organizaciones de salud con recursos limitados (Yılmaz, 2024).

Yılmaz (2024) sostiene que la adopción de soluciones abiertas puede generar beneficios económicos significativos al disminuir la dependencia de proveedores externos y facilitar la optimización de recursos tecnológicos. De manera complementaria, Chen y Zhou (2025) argumentan que los modelos colaborativos de desarrollo permiten acelerar la innovación y aumentar la capacidad de adaptación de las herramientas a diferentes contextos de aplicación.

Otra ventaja importante radica en la flexibilidad que ofrece este tipo de software. Los usuarios pueden modificar funcionalidades específicas, incorporar nuevos algoritmos o adaptar las plataformas a requerimientos particulares sin depender exclusivamente de actualizaciones comerciales. Esta capacidad de personalización resulta especialmente valiosa en proyectos de investigación donde frecuentemente se requiere implementar soluciones ajustadas a necesidades técnicas concretas (Fortunato & Galassi, 2021).

En el ámbito de la imagenología médica, las herramientas de código abierto han facilitado la integración de modelos de inteligencia artificial, sistemas de anotación médica y entornos de análisis de imágenes diagnósticas. Bridge et al. (2021) destacan que las bibliotecas abiertas favorecen la interoperabilidad y la estandarización de procesos relacionados con el desarrollo de aplicaciones para radiología y patología digital.

Asimismo, Kathiravelu et al. (2020) señalan que los entornos abiertos permiten construir y validar modelos de aprendizaje automático utilizando imágenes médicas obtenidas en escenarios clínicos reales, fortaleciendo la investigación aplicada y el desarrollo de nuevas soluciones tecnológicas para el sector salud.

Además, la disponibilidad abierta del código favorece la transparencia en el desarrollo de algoritmos de inteligencia artificial y procesamiento de imágenes médicas, permitiendo una evaluación más rigurosa de los resultados obtenidos y fortaleciendo la confianza en los sistemas desarrollados (Fortunato & Galassi, 2021).

Aplicaciones del Software Open Source en el Procesamiento de Imágenes Médicas

El avance de la inteligencia artificial y de la visión por computador ha impulsado la utilización de diversas herramientas open source para el procesamiento de imágenes médicas. Actualmente, numerosas investigaciones emplean bibliotecas y plataformas de código abierto para desarrollar algoritmos orientados a la clasificación, segmentación, reconstrucción y análisis automatizado de estudios radiológicos.

Entre las herramientas más utilizadas destacan OpenCV, TensorFlow y PyTorch, las cuales proporcionan recursos especializados para el desarrollo de modelos de aprendizaje automático y aprendizaje profundo aplicados a imágenes médicas. Estas plataformas han facilitado la construcción de prototipos capaces de detectar anomalías, identificar artefactos y mejorar la calidad visual de diferentes modalidades diagnósticas.

La literatura reciente evidencia que muchos de los avances alcanzados en detección automatizada de artefactos se han apoyado en tecnologías abiertas que permiten implementar redes neuronales profundas y algoritmos avanzados de procesamiento de imágenes (Ahmad et al., 2021; Elhanashi et al., 2025). De igual manera, investigaciones relacionadas con la reducción de artefactos metálicos han demostrado resultados prometedores mediante modelos computacionales desarrollados sobre plataformas abiertas de inteligencia artificial (Wang et al., 2021; Wajer et al., 2024).

Estos avances reflejan el potencial del software open source como herramienta para acelerar la investigación y facilitar el desarrollo de soluciones tecnológicas aplicadas al diagnóstico por imágenes.

Desafíos para su Implementación en Entornos Clínicos

A pesar de las ventajas asociadas al software open source, su implementación en escenarios clínicos también enfrenta diversos desafíos. Uno de los principales aspectos a considerar corresponde a los procesos de validación y certificación necesarios para garantizar la seguridad, confiabilidad y efectividad de las herramientas utilizadas en la atención de pacientes (Aldhafeeri, 2025).

Las aplicaciones destinadas al apoyo diagnóstico deben cumplir requisitos relacionados con calidad, trazabilidad, protección de datos, transparencia algorítmica y desempeño clínico. En consecuencia, la disponibilidad abierta del código no exime a estas herramientas de cumplir los estándares regulatorios exigidos por organismos nacionales e internacionales encargados de supervisar el uso seguro de tecnologías médicas (Aldhafeeri, 2025).

Otro desafío importante se relaciona con la necesidad de disponer de personal capacitado para implementar, adaptar y mantener este tipo de sistemas dentro de las instituciones de salud. Aunque el acceso al código fuente amplía las posibilidades de personalización, también requiere conocimientos técnicos especializados para garantizar un funcionamiento adecuado y una integración segura con los flujos de trabajo clínicos existentes (Lundström & Lindvall, 2023).

Adicionalmente, la incorporación de herramientas basadas en inteligencia artificial demanda mecanismos permanentes de monitoreo y control de calidad que permitan verificar su desempeño una vez implementadas en entornos reales. Dean et al. (2025) destacan que la

supervisión continua constituye un elemento fundamental para garantizar la confiabilidad y seguridad de los sistemas utilizados en la práctica radiológica.

Por esta razón, numerosos proyectos de investigación continúan enfocándose en evaluar rigurosamente el desempeño de herramientas open source antes de promover su incorporación a contextos clínicos reales, especialmente cuando están involucrados procesos relacionados con el diagnóstico médico. Este proceso de validación resulta indispensable para asegurar que las soluciones tecnológicas ofrezcan resultados consistentes, reproducibles y clínicamente seguros (Antonissen et al., 2026)

Relevancia del Software Open Source para la Corrección de Artefactos en Radiografía Digital

La corrección de artefactos constituye una de las áreas donde el software open source presenta un importante potencial de desarrollo dentro de la radiología digital. La disponibilidad de bibliotecas especializadas en procesamiento de imágenes, aprendizaje automático e inteligencia artificial ha permitido el diseño de herramientas capaces de identificar alteraciones técnicas que afectan la calidad diagnóstica de los estudios radiológicos. Estas capacidades han favorecido la creación de soluciones accesibles para la automatización de procesos de control de calidad en imagen médica (Bridge et al., 2021).

En el ámbito de la detección automática de artefactos, Ahmad et al. (2021) desarrollaron modelos basados en aprendizaje profundo capaces de identificar defectos presentes en imágenes médicas mediante el análisis automatizado de características visuales complejas. Sus resultados evidenciaron que estos sistemas pueden alcanzar niveles de desempeño comparables a los obtenidos mediante evaluación especializada.

Por otra parte, Wang et al. (2021) demostraron que las redes neuronales profundas pueden emplearse para reducir significativamente la presencia de artefactos metálicos en

imágenes tomográficas. Los autores reportaron mejoras en la calidad visual de las imágenes procesadas y una mayor preservación de la información anatómica relevante para la interpretación diagnóstica.

De manera complementaria, Wajer et al. (2024) señalan que la integración de inteligencia artificial en los procesos de corrección de imágenes constituye una estrategia prometedora para disminuir el impacto de los artefactos y optimizar la calidad diagnóstica. Según estos autores, los avances recientes en aprendizaje profundo permiten desarrollar métodos cada vez más precisos para restaurar imágenes afectadas por diferentes tipos de distorsiones.

Asimismo, el uso de plataformas abiertas favorece la reproducibilidad científica y la adaptación de algoritmos a diferentes necesidades clínicas e investigativas. Fortunato y Galassi (2021) destacan que la disponibilidad del código fuente facilita la validación independiente de los sistemas desarrollados, promoviendo una mayor transparencia en los procesos de investigación y desarrollo tecnológico.

La evidencia disponible sugiere que los prototipos desarrollados mediante software open source representan una alternativa viable para fortalecer los procesos de detección y corrección de artefactos en radiología digital. Su combinación con técnicas de inteligencia artificial permite explorar soluciones accesibles, flexibles y reproducibles, cuyo análisis resulta fundamental para determinar su efectividad, limitaciones y potencial aplicabilidad dentro de los servicios de diagnóstico por imágenes.

Marco Metodológico

Tipo y Diseño de la Investigación

Esta investigación corresponde a un estudio de carácter aplicado con alcance descriptivo-comparativo. Su propósito es examinar el desempeño de herramientas de software open source utilizadas para la detección y corrección de artefactos en imágenes de radiografía digital, con el fin de identificar sus características, ventajas, limitaciones y posibilidades de aplicación en el contexto radiológico.

El estudio se desarrolló mediante un diseño documental de tipo analítico, basado en la revisión y evaluación crítica de literatura científica especializada. De acuerdo con Arias (2012), la investigación documental se fundamenta en la recopilación, organización e interpretación sistemática de información proveniente de fuentes secundarias, permitiendo generar nuevo conocimiento a partir de evidencia previamente publicada.

Desde esta perspectiva, la investigación no se orientó a la obtención de datos experimentales propios, sino al análisis de estudios científicos relacionados con inteligencia artificial, procesamiento digital de imágenes y herramientas de código abierto aplicadas al control de calidad en radiología. Según Bernal (2016), este tipo de diseño permite examinar críticamente información existente para identificar tendencias, relaciones y aportes relevantes sobre un fenómeno determinado.

Asimismo, la investigación posee un alcance descriptivo-comparativo, ya que busca caracterizar las principales herramientas reportadas en la literatura y comparar aspectos relacionados con su funcionamiento, desempeño y aplicabilidad clínica. Este tipo de estudios permite analizar similitudes y diferencias entre diversas propuestas tecnológicas con el fin de obtener una comprensión más amplia del objeto de estudio (Hernández-Sampieri & Mendoza, 2018).

Enfoque de Investigación

La investigación se desarrolló bajo un enfoque cualitativo con apoyo de elementos cuantitativos. El componente cualitativo permitió interpretar las características técnicas, metodológicas y funcionales de las herramientas de software analizadas, así como comprender las tendencias actuales relacionadas con la automatización de procesos en imágenes médicas.

De manera complementaria, se incorporaron elementos cuantitativos a partir de las métricas de desempeño reportadas en los estudios seleccionados, entre ellas precisión, sensibilidad, especificidad, F-score y área bajo la curva ROC. La integración de estos indicadores facilitó la comparación objetiva entre diferentes propuestas tecnológicas y contribuyó a valorar su efectividad en la detección y corrección de artefactos.

La combinación de ambos enfoques favoreció una evaluación más amplia de la evidencia científica disponible, permitiendo interpretar los hallazgos desde una perspectiva técnica y clínica.

Población y Unidad de Análisis

La población estuvo conformada por la producción científica relacionada con la detección y corrección de artefactos en imágenes médicas mediante técnicas de procesamiento digital de imágenes, inteligencia artificial y herramientas de software open source. Se consideraron artículos científicos, revisiones especializadas, estudios experimentales y documentos técnicos localizados en bases de datos académicas de reconocido prestigio. La unidad de análisis correspondió a cada uno de los estudios seleccionados durante el proceso de revisión documental. Estos documentos fueron examinados de manera individual para identificar aspectos como el tipo de artefacto abordado, las metodologías implementadas, las herramientas utilizadas, las métricas de evaluación empleadas y los resultados obtenidos. El

análisis de estas variables permitió establecer comparaciones entre diferentes enfoques tecnológicos y valorar su potencial aplicación en el ámbito de la radiología digital.

Criterios de Selección Documental

La selección de los documentos analizados se realizó mediante criterios previamente definidos con el propósito de garantizar la pertinencia, actualidad y calidad científica de la información recopilada. Se incluyeron artículos científicos publicados entre 2020 y 2025 en revistas indexadas, repositorios académicos y bases de datos especializadas que abordaran la detección o corrección de artefactos en imágenes médicas mediante técnicas de procesamiento digital de imágenes, aprendizaje automático o inteligencia artificial. Asimismo, se consideraron estudios que presentaran resultados experimentales y reportaran indicadores de desempeño, tales como precisión, sensibilidad, especificidad, F-score o área bajo la curva ROC.

Por otra parte, se excluyeron documentos sin respaldo científico verificable, publicaciones duplicadas, estudios sin acceso al texto completo y trabajos cuyo objeto de estudio no guardara relación directa con la detección o corrección de artefactos en imágenes médicas. De igual manera, fueron descartadas aquellas investigaciones que no presentaban procesos de validación o resultados que permitieran evaluar el rendimiento de las herramientas analizadas.

Fuentes y Técnicas de Recolección de Información

La recolección de información se realizó a partir de fuentes secundarias de carácter científico, obtenidas mediante la consulta de bases de datos académicas reconocidas internacionalmente, entre ellas Scopus, PubMed, ScienceDirect, IEEE Xplore, Google Scholar y SciELO. Estas plataformas fueron seleccionadas por su cobertura en áreas relacionadas con radiología, informática médica, inteligencia artificial y procesamiento de imágenes.

La técnica de recolección empleada fue la revisión documental estructurada, la cual permitió identificar, seleccionar y analizar investigaciones relevantes para el desarrollo del estudio. La estrategia de búsqueda se fundamentó en la combinación de términos relacionados con artefactos radiológicos, procesamiento de imágenes médicas, inteligencia artificial y software open source, utilizando operadores booleanos para optimizar la localización de documentos pertinentes.

La información obtenida fue organizada mediante una matriz de análisis documental diseñada para registrar aspectos como autoría, año de publicación, objetivo del estudio, metodología empleada, tipo de artefacto evaluado, herramienta utilizada, métricas de desempeño y principales hallazgos. Este procedimiento facilitó la sistematización y posterior comparación de la evidencia científica recopilada.

Técnicas de Análisis de la Información

El análisis de la información se desarrolló mediante una estrategia cualitativa de carácter comparativo y analítico. Inicialmente, los estudios seleccionados fueron examinados para identificar las características de las herramientas de software open source empleadas en la detección y corrección de artefactos, así como los enfoques tecnológicos utilizados en su implementación. Posteriormente, se realizó una comparación entre las diferentes propuestas encontradas en la literatura científica, considerando variables como el tipo de artefacto abordado, los algoritmos utilizados, las métricas de evaluación reportadas y los resultados obtenidos. Este proceso permitió reconocer similitudes, diferencias y tendencias en el desarrollo de soluciones orientadas al mejoramiento de la calidad de las imágenes radiológicas. De forma complementaria, se aplicó el análisis de contenido para clasificar la información en categorías temáticas relacionadas con inteligencia artificial, procesamiento digital de imágenes, métodos de reducción de artefactos, desempeño diagnóstico y

aplicabilidad clínica. Según Bardin (2002), esta técnica facilita la interpretación sistemática de la información y la identificación de patrones significativos dentro de un conjunto documental. Finalmente, los hallazgos fueron integrados mediante una síntesis interpretativa que permitió establecer conclusiones fundamentadas sobre el estado actual de las herramientas open source destinadas a la corrección de artefactos en radiología digital.

Procedimiento Metodológico

El desarrollo de la investigación se llevó a cabo mediante un proceso secuencial compuesto por varias etapas interrelacionadas.

Inicialmente se definió el problema de investigación y se formularon los objetivos que orientaron el estudio. Posteriormente, se realizó la búsqueda sistemática de literatura científica en bases de datos especializadas, aplicando los criterios de inclusión y exclusión establecidos previamente. Una vez seleccionados los documentos, se procedió a la organización y sistematización de la información mediante una matriz de análisis documental. Esta herramienta permitió registrar de manera estructurada las principales características de cada estudio y facilitar su posterior evaluación. En una etapa posterior se efectuó el análisis comparativo y la categorización temática de la información recopilada, identificando tendencias, enfoques metodológicos, métricas de evaluación y resultados reportados en la literatura. Finalmente, se realizó una síntesis crítica de los hallazgos con el propósito de establecer conclusiones sobre el desempeño, las ventajas, las limitaciones y la aplicabilidad de las herramientas de software open source utilizadas para la detección y corrección de artefactos en imágenes de radiografía digital

Resultados

Caracterización de Artefactos y Herramientas

Frecuencia e Impacto

A partir de la revisión de literatura científica reciente, se observa que los artefactos en radiografía digital constituyen una limitación relevante para la calidad diagnóstica, ya que pueden distorsionar la representación de las estructuras anatómicas. De acuerdo con Kumari et al. (2024), estos no corresponden a la anatomía del paciente, sino que se generan durante las etapas de adquisición, reconstrucción o procesamiento de la imagen.

Entre los artefactos reportados con mayor frecuencia se encuentran el ruido de imagen, las distorsiones geométricas, las líneas o bandas asociadas a fallos del detector, los artefactos metálicos y aquellos provocados por el movimiento del paciente. Su aparición no responde a una única causa, sino a la interacción entre factores técnicos del equipo y condiciones propias del paciente durante la toma del estudio.

Ahora bien, el impacto de estos artefactos no es homogéneo. Los artefactos metálicos, por ejemplo, suelen afectar de manera más crítica la calidad de la imagen, ya que pueden generar zonas de sombra que ocultan estructuras cercanas a implantes o prótesis (Kumari et al., 2024). En cambio, en contextos clínicos con alta carga de trabajo, tienden a predominar problemas como el ruido de imagen y los errores de adquisición, cuya frecuencia aumenta con el volumen de estudios realizados, tal como describen Inkinen et al. (2024).

El movimiento del paciente también representa un factor importante, debido a que produce imágenes borrosas que disminuyen la precisión diagnóstica y, en muchos casos, obligan a repetir el estudio. En conjunto, estos hallazgos sugieren que la relevancia de cada artefacto depende tanto de su frecuencia como de su impacto sobre la calidad final de la imagen, lo que resulta clave para orientar el desarrollo de herramientas de detección y

corrección automatizada. Además, la aparición de estos artefactos está directamente relacionada con factores técnicos como la calibración del equipo, los parámetros de adquisición (kVp, mAs) y el tipo de detector, así como con condiciones propias del paciente, como el movimiento, la presencia de implantes metálicos o la dificultad para mantener la posición durante el estudio. Esta interacción no solo afecta la calidad de la imagen, sino que puede comprometer la detección de lesiones, generando errores diagnósticos o la necesidad de repetir estudios.

Tabla 1

Caracterización de los Principales Artefactos en Radiografía Digital Reportados en la Literatura Científica

Tipo de Artefacto	Fuente	Origen Principal	Efecto Sobre la Imagen	Consecuencia Diagnóstica	Nivel de Impacto
Ruido de imagen	Kumari et al. (2024)	Baja dosis de radiación y limitaciones del detector	Apariencia granulada y pérdida de detalle fino	Disminución de la visibilidad de estructuras anatómicas pequeñas	Alto
Artefacto por movimiento	Inkinen et al. (2024)	Movimiento involuntario del paciente durante la adquisición	Desenfoque y pérdida de nitidez	Posibles errores diagnósticos y repetición del estudio	Alto
Artefacto metálico	Wajer et al. (2024); Kumari et al. (2024)	Presencia de implantes, prótesis o dispositivos metálicos	Sombras, bandas brillantes y distorsión local	Ocultamiento de estructuras anatómicas adyacentes	Muy alto

Distorsión geométrica	Kumari et al. (2024)	Errores de posicionamiento y reconstrucción de imagen	Alteración de la forma y tamaño de estructuras	Interpretación anatómica incorrecta	Moderado
Líneas o bandas	Inkinen et al. (2024)	Fallos de calibración o defectos del detector digital	Aparición de franjas visibles sobre la imagen	Interferencia en la visualización diagnóstica	Moderado
Artefactos asociados al detector	Inkinen et al. (2024)	Defectos electrónicos o desgaste del sistema de captura	Píxeles defectuosos y pérdida de uniformidad	Reducción de la calidad diagnóstica global	Moderado-Alto

Nota. Síntesis elaborada a partir de los estudios revisados sobre artefactos en radiografía digital. Se presentan los principales tipos de artefactos reportados, sus causas técnicas, efectos sobre la calidad de imagen y posibles repercusiones diagnósticas. Información adaptada de Kumari et al. (2024), Inkinen et al. (2024) y Wajer et al. (2024).

Inventario de Software

La literatura revisada evidencia diversas herramientas de código abierto utilizadas en el procesamiento, detección y corrección de artefactos en imágenes de radiografía digital. Su uso ha aumentado en los últimos años, principalmente por su flexibilidad y capacidad de adaptación a modelos de inteligencia artificial, como señalan Fortunato & Galassi (2021) y Chen & Zhou (2025).

Entre las herramientas más utilizadas destaca *OpenCV*, ampliamente empleada en tareas de procesamiento de imágenes como filtrado, segmentación y mejora de calidad visual. Asimismo, frameworks como *TensorFlow* y *PyTorch* permiten desarrollar modelos basados en

redes neuronales convolucionales, especialmente útiles para la detección automática de artefactos.

Algunos estudios específicos reportan el uso de arquitecturas más específicas. Por ejemplo, Wang et al. (2021) proponen DAN-Net, un modelo diseñado para la reducción de artefactos metálicos mediante el análisis en dominio dual, lo que permite mejorar la imagen sin perder información anatómica relevante. De manera similar, Ahmad et al. (2021) describen modelos como 3D-QCNet, orientados a la detección automática de artefactos en imágenes tridimensionales.

En síntesis, los estudios analizados evidencian una clara predominancia de enfoques basados en deep learning, particularmente redes neuronales convolucionales. Esta tendencia coincide con lo planteado por Elhanashi et al. (2025), quienes destacan el papel creciente de estos modelos en el análisis automatizado de imágenes médicas.

Tabla 2

Herramientas Open Source Utilizadas para la Detección y Corrección de Artefactos en Imágenes Médicas

Herramienta	Referencia (APA 7. ^a ed.)	Tipo de Tecnología	Función Principal	Aplicación en Radiología
OpenCV	Chen y Zhou (2025)	Visión por computador	Procesamiento y mejora de imágenes	Filtrado, segmentación y reducción de ruido
TensorFlow	Elhanashi et al. (2025)	Deep Learning	Desarrollo de modelos de inteligencia artificial	Detección automática de artefactos

PyTorch	Elhanashi et al. (2025)	Deep Learning	Entrenamiento de redes neuronales	Clasificación y análisis de imágenes médicas
DAN-Net	Wang et al. (2021)	Red neuronal de dominio dual	Reducción de artefactos metálicos	Tomografía computarizada y radiología digital
3D-QCNet	Ahmad et al. (2021)	Red neuronal tridimensional	Detección automatizada de artefactos	Control de calidad en imágenes médicas

Nota. La tabla resume las principales herramientas y arquitecturas identificadas en la literatura científica para la detección y corrección automatizada de artefactos. Se incluyen tecnologías de procesamiento digital de imágenes, aprendizaje profundo y redes neuronales especializadas reportadas por Ahmad et al. (2021), Wang et al. (2021), Elhanashi et al. (2025) y Chen y Zhou (2025).

Desempeño Técnico

Comparativa de Eficacia

A partir de los estudios analizados, se observa que los modelos basados en inteligencia artificial presentan un mejor desempeño en la detección de artefactos en radiografía digital en comparación con los métodos manuales tradicionales. Según Ahmad et al. (2021) y Elhanashi et al. (2025), estos sistemas permiten una identificación más consistente de alteraciones en la imagen, reduciendo la variabilidad asociada a la interpretación humana.

En los métodos manuales, aunque siguen siendo fundamentales en la práctica clínica, los resultados dependen en gran medida de la experiencia del profesional, lo que puede generar diferencias en la detección de artefactos entre observadores. En contraste, los modelos de inteligencia artificial, especialmente aquellos entrenados con grandes volúmenes de datos, ofrecen resultados más estables en condiciones similares.

Los valores de desempeño reportados en la literatura sitúan a los modelos de deep learning en rangos oscilan entre el 85 % y 95 %. Estos resultados son comparables con los de sistemas propietarios, que en algunos casos alcanzan valores ligeramente superiores, aunque con menor accesibilidad y mayor costo de implementación. No obstante, es importante señalar que estos rangos pueden variar dependiendo del tipo de artefacto analizado, la calidad de los datos de entrenamiento y el entorno clínico en el que se aplican.

Tabla 3

Comparación del Desempeño Reportado Entre Métodos Manuales, Soluciones Open Source Basadas en Inteligencia Artificial y Software Propietario

Método de Evaluación	Referencia	Precisión Reportada	Sensibilidad Reportada	Especificidad Reportada	Principales Características
Evaluación manual realizada por especialistas	Inkinen et al. (2024); Elhanashi et al. (2025)	70 %–85 %	Variable según experiencia del observador	Variable según el contexto clínico	Dependencia de la experiencia profesional y posibilidad de variabilidad entre evaluadores
Herramientas open source basadas en inteligencia artificial	Ahmad et al. (2021); Elhanashi et al. (2025)	85 %–95 %	Alta	Alta	Automatización del análisis, reducción de errores humanos y mayor consistencia en los resultados
Software propietario basado en	Cancian et al. (2025);	88 %–96 %	Muy alta	Muy alta	Alto desempeño técnico, aunque con mayores

inteligencia artificial	Wajer et al. (2024)				costos de adquisición y mantenimiento
Modelos de deep learning especializados (CNN y arquitecturas avanzadas)	Ahmad et al. (2021); Cancian et al. (2025)	Superior al 90 % en condiciones controladas	Muy alta	Muy alta	Capacidad para identificar patrones complejos y clasificar automáticamente diferentes tipos de artefactos

Nota. Los valores presentados corresponden a rangos de desempeño reportados en los estudios analizados y pueden variar según el tipo de artefacto, el conjunto de datos utilizado para entrenamiento y validación, así como las condiciones clínicas de aplicación. La evidencia revisada muestra que las herramientas open source basadas en inteligencia artificial alcanzan niveles de precisión cercanos a los obtenidos por soluciones propietarias, reduciendo la brecha de desempeño a diferencias aproximadas entre el 2 % y el 5 % (Ahmad et al., 2021; Cancian et al., 2025; Elhanashi et al., 2025).

En este contexto, Cancian et al. (2025) señalan que los modelos de inteligencia artificial pueden igualar o incluso superar la evaluación humana en tareas específicas, particularmente cuando se emplean arquitecturas avanzadas y conjuntos de datos amplios. Sin embargo, estos resultados deben interpretarse con cautela, ya que no siempre se replican de la misma manera en todos los entornos clínicos.

En términos metodológicos, los estudios revisados presentan en su mayoría diseños experimentales y validaciones con conjuntos de datos amplios, lo que respalda la confiabilidad

de los resultados. Sin embargo, la heterogeneidad de los datasets y la falta de estandarización limitan la comparabilidad entre estudios y su generalización a distintos contextos clínicos.

Un aspecto crítico en el uso de modelos de deep learning es su limitada interpretabilidad, conocida como el problema de la “caja negra”. Aunque estos modelos pueden alcanzar altos niveles de precisión, no siempre permiten comprender cómo se llega a una decisión. En el contexto clínico, esto representa un desafío, ya que los profesionales requieren transparencia para respaldar sus diagnósticos. Por ello, han surgido enfoques de inteligencia artificial explicable (XAI), orientados a mejorar la confianza y la fiabilidad en la toma de decisiones médicas.

Análisis Por Tipo de Artefacto

La efectividad de los algoritmos de detección y corrección no es uniforme, sino que depende del tipo de artefacto presente en la imagen. Diversos estudios coinciden en que algunas distorsiones son más complejas de tratar que otras, lo que influye directamente en el rendimiento de los modelos.

En el caso del ruido de imagen, los enfoques que combinan filtros digitales con redes neuronales convolucionales han mostrado buenos resultados, ya que permiten reducir la interferencia sin eliminar detalles relevantes (Kumari et al., 2024). Para los artefactos asociados al movimiento del paciente, las redes neuronales también presentan un desempeño sólido, debido a su capacidad para reconocer patrones de desenfoque y distorsión (Elhanashi et al., 2025).

Los artefactos metálicos, por otro lado, siguen representando uno de los mayores desafíos. Según Wang et al. (2021), los modelos basados en dominio dual, como DAN-Net, logran mejores resultados al reducir este tipo de distorsiones sin comprometer la información anatómica, lo cual es clave para mantener la utilidad diagnóstica de la imagen.

En cuanto a las distorsiones geométricas, los modelos de deep learning han mostrado un desempeño adecuado, aunque su efectividad depende en gran medida de la calidad y diversidad de los datos utilizados durante el entrenamiento, como señalan Ahmad et al. (2021).

En conjunto, estos hallazgos indican que no existe una única solución aplicable a todos los casos. Por el contrario, la selección del método más adecuado depende del tipo de artefacto y del contexto en el que se utilice, lo que refuerza la necesidad de desarrollar soluciones flexibles que integren múltiples enfoques.

Tabla 4

Técnicas de Detección y Corrección de Artefactos Según el Tipo de Alteración Radiológica

Tipo de Artefacto	Técnica Predominante Reportada	Referencia	Principio de Funcionamiento	Ventaja Principal
Ruido de imagen	Filtros digitales combinados con redes neuronales convolucionales (CNN)	Kumari et al. (2024)	Reduce señales no deseadas y preserva información anatómica relevante mediante aprendizaje automático	Mejora la calidad visual sin afectar significativamente los detalles diagnósticos
Movimiento del paciente	Redes neuronales convolucionales (CNN)	Elhanashi et al. (2025)	Identifica patrones de desenfoque y corrige distorsiones asociadas al movimiento durante la adquisición	Incrementa la nitidez de la imagen y reduce la necesidad de repetir estudios
Artefactos metálicos	Arquitecturas de dominio dual (DAN-Net)	Wang et al. (2021)	Analiza simultáneamente el dominio espacial y	Conserva estructuras anatómicas

			el dominio de proyección para minimizar distorsiones producidas por materiales metálicos	cercanas a implantes y prótesis
Distorsión geométrica	Modelos de deep learning	Ahmad et al. (2021)	Aprende patrones complejos de deformación mediante entrenamiento supervisado con grandes volúmenes de datos	Mejora la representación anatómica y la precisión diagnóstica
Artefactos múltiples o combinados	Modelos híbridos de inteligencia artificial	Cancian et al. (2025)	Integran diferentes representaciones de imagen para detectar y clasificar simultáneamente distintos niveles de severidad	Mayor capacidad de adaptación a escenarios clínicos complejos

Nota. La literatura revisada evidencia que las técnicas fundamentadas en inteligencia artificial y aprendizaje profundo constituyen actualmente los enfoques con mejores resultados para la detección y corrección de artefactos en imágenes médicas. La selección de la técnica depende del tipo de artefacto, de la calidad de los datos de entrenamiento y de las condiciones clínicas de aplicación. Información sintetizada a partir de Ahmad et al. (2021), Wang et al. (2021), Kumari et al. (2024), Elhanashi et al. (2025) y Cancian et al. (2025).

Los resultados indican una diferencia moderada entre software open source y propietario (2–5% en precisión), lo que sugiere que la brecha de desempeño se ha reducido significativamente en modelos basados en deep learning.

A pesar de esta diferencia, desde una perspectiva clínica, una variación del 2–5% en precisión no siempre representa un cambio significativo en la toma de decisiones médicas, especialmente en contextos con limitaciones de recursos. En este sentido, las herramientas open source pueden considerarse una alternativa viable y costo-efectiva, siempre que se garantice su adecuada validación clínica.

Factores de Aplicabilidad Clínica.

Costo y Accesibilidad

La literatura revisada coincide en que el software open source representa una alternativa más accesible frente a los sistemas propietarios utilizados en el procesamiento de imágenes médicas. De acuerdo con Fortunato & Galassi (2021) y Yılmaz (2024), este tipo de herramientas elimina los costos asociados a licencias comerciales y permite una mayor flexibilidad en su implementación.

Este aspecto resulta especialmente relevante en instituciones con recursos limitados, donde la adquisición de software especializado puede ser una barrera importante. En estos contextos, el uso de soluciones open source facilita el acceso a tecnologías basadas en inteligencia artificial sin requerir grandes inversiones iniciales. Sin embargo, esta ventaja económica no implica necesariamente una implementación sencilla, ya que pueden surgir otros costos indirectos relacionados con infraestructura, capacitación o mantenimiento.

Además de la ausencia de costos de licencia, el uso de software open source implica costos indirectos relevantes. Por ejemplo, la infraestructura tecnológica requiere equipos con alta capacidad de procesamiento (como GPU), especialmente para modelos de deep learning.

Asimismo, es necesario invertir en la capacitación del personal en lenguajes de programación y frameworks como TensorFlow o PyTorch. Finalmente, el mantenimiento del sistema, actualizaciones y soporte técnico interno pueden generar costos adicionales que deben ser considerados en la implementación clínica.

Desafíos Técnicos

Hallazgos sobre la necesidad de soporte técnico, validación regulatoria (FDA/CE) y la curva de aprendizaje para el personal médico. A pesar de sus ventajas, la implementación de software open source en entornos clínicos presenta varios desafíos que deben considerarse. Uno de los principales es la necesidad de validación bajo estándares regulatorios internacionales, como los establecidos por entidades tipo FDA o certificaciones CE. Este proceso es fundamental para garantizar la seguridad y confiabilidad de las herramientas antes de su uso en diagnóstico médico (Fortunato & Galassi, 2021).

Otro aspecto relevante es la necesidad de personal capacitado. A diferencia de muchos sistemas propietarios, que suelen ofrecer soluciones más cerradas y fáciles de usar, las herramientas open source requieren conocimientos técnicos en programación, procesamiento de imágenes y manejo de modelos de inteligencia artificial. Como señalan Elhanashi et al. (2025), esta curva de aprendizaje puede limitar su adopción en algunos entornos clínicos.

La integración con sistemas hospitalarios existentes también representa un reto. La compatibilidad con estándares como PACS y DICOM no siempre es directa, lo que puede generar dificultades en la interoperabilidad y en la incorporación de estas herramientas dentro de los flujos de trabajo clínicos habituales, tal como indican Chen & Zhou (2025).

Por ejemplo, en un hospital que utiliza un sistema PACS propietario, la implementación de una herramienta open source para la detección de artefactos puede presentar dificultades en la lectura de archivos DICOM debido a diferencias en la codificación

o en los metadatos. Esto puede requerir el desarrollo de interfaces intermedias o procesos de conversión de formato, lo que incrementa la complejidad técnica y retrasa su integración en el flujo clínico.

Tabla 5

Factores que Influyen en la Aplicabilidad Clínica de Herramientas Open Source para la Detección y Corrección de Artefactos en Imágenes Radiológicas

Factor de Aplicabilidad	Referencia	Descripción del Factor	Implicación para la Implementación Clínica	Posible Impacto Institucional
Validación clínica	Fortunato y Galassi (2021)	Los algoritmos deben someterse a procesos de validación técnica y clínica antes de ser utilizados en entornos asistenciales.	Garantiza la confiabilidad diagnóstica y la seguridad del paciente.	Mayor aceptación institucional y cumplimiento de estándares regulatorios.
Capacitación del personal	Elhanashi et al. (2025)	El uso de herramientas basadas en inteligencia artificial requiere conocimientos en interpretación de resultados y manejo de software especializado.	Facilita la integración adecuada de los sistemas en la práctica clínica diaria.	Incremento de competencias tecnológicas y reducción de errores operativos.

Integración con sistemas hospitalarios	Chen y Zhou (2025)	<p>La interoperabilidad con plataformas PACS y estándares DICOM es necesaria para incorporar las herramientas al flujo de trabajo radiológico.</p>	Permite el intercambio eficiente de imágenes y datos clínicos.	Optimización de procesos y continuidad operativa.
Infraestructura tecnológica	Yilmaz (2024)	<p>Los modelos de aprendizaje profundo suelen requerir equipos con capacidad de procesamiento avanzada y almacenamiento adecuado.</p>	Condiciona el rendimiento y la velocidad de ejecución de los algoritmos.	Inversión adicional en hardware y recursos computacionales.
Soporte técnico y mantenimiento	Fortunato y Galassi (2021)	<p>Las soluciones open source dependen de actualizaciones continuas y seguimiento técnico para garantizar su funcionamiento.</p>	Favorece la estabilidad y sostenibilidad del sistema a largo plazo.	Reducción de fallos operativos y mejora de la continuidad del servicio.
Cumplimiento normativo	Fortunato y Galassi (2021)	<p>Las aplicaciones destinadas al ámbito médico deben ajustarse a requisitos</p>	Facilita la adopción formal de las herramientas en	Mayor confianza institucional y respaldo legal para su utilización.

regulatorios y estándares de calidad internacionales.	instituciones de salud.
--	----------------------------

Nota. La aplicabilidad clínica de las herramientas open source no depende exclusivamente de su desempeño técnico, sino también de factores relacionados con la validación científica, la infraestructura tecnológica disponible, la capacitación de los usuarios, la interoperabilidad con sistemas hospitalarios y el cumplimiento de normativas regulatorias. Información sintetizada a partir de Fortunato y Galassi (2021), Elhanashi et al. (2025), Chen y Zhou (2025) y Yılmaz (2024).

En conjunto, el software open source ofrece ventajas claras en términos de costo y flexibilidad, lo que lo convierte en una opción atractiva, especialmente en contextos con recursos limitados. No obstante, su adopción en la práctica clínica no depende únicamente de su rendimiento técnico, sino también de factores organizacionales, regulatorios y de capacitación que pueden condicionar su implementación real.

Recomendaciones para la implementación clínica

Priorizar el uso de herramientas open source en instituciones con recursos limitados.
Garantizar procesos de validación clínica antes de su implementación.

Capacitar al personal en el uso de herramientas basadas en inteligencia artificial.

Evaluar la relación costo-beneficio frente a software propietario.

Asegurar la compatibilidad con sistemas hospitalarios (PACS/DICOM).

Limitaciones y Perspectivas Futuras

Como limitación, esta revisión se basa en estudios recientes que pueden no reflejar completamente la variabilidad de todos los entornos clínicos. Asimismo, la falta de

estandarización en los datos de entrenamiento representa un desafío importante para la generalización de los modelos de inteligencia artificial.

En cuanto a perspectivas futuras, se espera un avance en el desarrollo de modelos híbridos, la creación de estándares para datasets médicos y el fortalecimiento de la inteligencia artificial explicable. Estos avances permitirán una adopción más segura, eficiente y confiable de estas tecnologías en la práctica clínica.

Conclusiones

La aplicación de la inteligencia artificial en la radiografía digital ha demostrado ser una herramienta altamente efectiva para mejorar la calidad de las imágenes diagnósticas, especialmente en la detección y corrección de artefactos. A lo largo del análisis realizado, se evidencia que estos sistemas permiten optimizar la visualización de estructuras anatómicas, lo que favorece una interpretación clínica más precisa. En este sentido, la integración de estas tecnologías no solo aporta valor técnico, sino que también contribuye directamente a la toma de decisiones médicas más confiables.

Los modelos basados en aprendizaje profundo se destacan por presentar un mejor desempeño en comparación con los métodos tradicionales, ya que logran niveles de precisión elevados en el procesamiento y análisis de imágenes médicas. Sin embargo, su efectividad no es absoluta, dado que depende en gran medida de la calidad, cantidad y diversidad de los datos utilizados para su entrenamiento. Esto implica que, aunque representan un avance significativo, es necesario considerar sus limitaciones para evitar sesgos o resultados poco generalizables en diferentes contextos clínicos.

El uso de software de código abierto se consolida como una alternativa viable dentro del ámbito de la inteligencia artificial aplicada a la salud, debido a que facilita el acceso a herramientas tecnológicas sin incurrir en altos costos de licenciamiento. Además, este tipo de software promueve la colaboración entre investigadores y profesionales, permitiendo la adaptación y mejora continua de los sistemas. Esto resulta especialmente relevante en contextos donde los recursos son limitados, ya que amplía las posibilidades de implementación en diferentes entornos.

La presencia de artefactos en radiografía digital continúa siendo un desafío importante en el campo del diagnóstico por imágenes, debido a que su origen es multifactorial,

incluyendo factores técnicos, errores en la adquisición de la imagen y condiciones propias del paciente. Estos artefactos pueden afectar significativamente la calidad de la imagen y, en consecuencia, la precisión diagnóstica. Por esta razón, se hace necesario el uso de herramientas avanzadas, como las basadas en inteligencia artificial, que permitan su identificación y corrección de manera más eficiente.

A pesar de los avances en el desarrollo de modelos de inteligencia artificial, aún existen limitaciones relacionadas con la interpretabilidad de estos sistemas, especialmente en aquellos basados en aprendizaje profundo. En muchos casos, estos modelos funcionan como “cajas negras”, lo que dificulta comprender cómo se llega a una determinada decisión. Esta situación puede generar desconfianza en el ámbito clínico, donde la transparencia y la justificación de los resultados son fundamentales, lo que plantea la necesidad de seguir investigando en modelos más explicables.

El análisis comparativo de herramientas evidencia que no existe una solución única aplicable a todos los contextos clínicos, ya que la selección del software depende de factores como el tipo de artefacto, los recursos disponibles y los objetivos del diagnóstico. Esto resalta la importancia de una evaluación previa antes de implementar cualquier tecnología, con el fin de garantizar su pertinencia y efectividad.

La variabilidad en el desempeño de los modelos de inteligencia artificial según el tipo de artefacto demuestra la necesidad de enfoques más especializados, capaces de adaptarse a condiciones específicas de las imágenes radiográficas. En este sentido, los resultados sugieren que el desarrollo futuro debe orientarse hacia modelos más robustos y personalizados que respondan a escenarios clínicos particulares.

La integración de la inteligencia artificial en la práctica radiológica no reemplaza el criterio profesional del especialista, sino que actúa como una herramienta de apoyo que

complementa el proceso diagnóstico. Por lo tanto, su uso adecuado requiere una interacción equilibrada entre la tecnología y el conocimiento clínico, fortaleciendo así la calidad de la atención en salud.

Referencias Bibliográficas

- Ahmad, A., Parker, D., Samani, Z. R., & Verma, R. (2021). 3D-QCNet: A pipeline for automated artifact detection in diffusion MRI images. *arXiv*.
<https://arxiv.org/abs/2103.05285>
- Antonissen, N., Tryfonos, O., Houben, I. B., Jacobs, C., de Rooij, M., & van Leeuwen, K. G. (2026). Artificial intelligence in radiology: 173 commercially available products and their scientific evidence. *European Radiology*, *36*, 526–536.
<https://pubmed.ncbi.nlm.nih.gov/40707732/>
- Aldhafeeri, F. M. (2025). Governing artificial intelligence in radiology: A systematic review of ethical, legal, and regulatory frameworks. *Diagnostics*, *15*(18), 2300.
<https://doi.org/10.3390/diagnostics15182300>
- Arias, F. G. (2012). El proyecto de investigación: Introducción a la metodología científica (6.^a ed.). *Episteme*.
https://tauniversity.org/sites/default/files/libro_el_proyecto_de_investigacion_de_fidias_g_arias.pdf
- Bernal, C. A. (2016). Metodología de la investigación: Administración, economía, humanidades y ciencias sociales (4.^a ed.). *Pearson Educación*.
<https://bibliotecadigital.utn.edu.ec/files/original/fb0b0cfee2ae990609933d17c6890848960051aa.pdf>
- Bridge, C. P., Gorman, C., Pieper, S., Doyle, S. W., Lennerz, J. K., Kalpathy-Cramer, J., Clunie, D. A., Fedorov, A. Y., & Herrmann, M. D. (2021). Highdicom: A Python library for standardized encoding of image annotations and machine learning model outputs in pathology and radiology. *arXiv*. <https://doi.org/10.1007/s10278-022-00683-y>

Bushberg, J. T., Seibert, J. A., Leidholdt, E. M., & Boone, J. M. (2011). The essential physics of medical imaging (3rd ed.). *Lippincott Williams & Wilkins*.

<https://pubmed.ncbi.nlm.nih.gov/28524933/>

Cancian, P., Saitta, S., Gu, X., van Herten, R. L. M., Luttikholt, T. J., Thannhauser, J., Volleberg, R., van der Waerden, R., van der Zande, J., van Ginneken, B., van Royen, N., & Išgum, I. (2025). Attenuation artifact detection and severity classification in intracoronary OCT using mixed image representations. *arXiv*.

<https://arxiv.org/abs/2503.05322>

Chen, X., & Zhou, Y. (2025). Open-source collaboration and technological innovation in the industrial software industry: A multi-case study. *Systems*, 13(6), 433.

<https://doi.org/10.3390/systems13060433>

Creswell, J. W. (2014). Research design: Qualitative, quantitative and mixed methods approaches (4th ed.). *Sage Publications*.

https://www.ucg.ac.me/skladiste/blog_609332/objava_105202/fajlovi/Creswell.pdf

Dean, G., Montañà, E., Kyriazi, S., Shelmerdine, S. C., Buckens, C. F., Agrell, H., Ranschaert, E., Marusic, A., Davies, G. J., Wardle, P., Schembri, N., Ganten, M., Labruto, F., & Jobke, B. (2025). Real-world monitoring of artificial intelligence in radiology: Challenges and best practices. *Korean Journal of Radiology*, 26(11), 1010–1021.

<https://pubmed.ncbi.nlm.nih.gov/41078022/>

Doi, K. (2007). Computer-aided diagnosis in medical imaging: Historical review, current status and future potential. *Computerized Medical Imaging and Graphics*, 31(4–5), 198–211. <https://www.sciencedirect.com/science/article/abs/pii/S0895611107000262>

Elhanashi, A., Saponara, S., Zheng, Q., Almutairi, N., Singh, Y., Kuanar, S., Ali, F., Unal, O., & Faghani, S. (2025). AI-powered object detection in radiology: Current models,

challenges, and future direction. *Journal of Imaging*, 11(5), 141.

<https://doi.org/10.3390/jimaging11050141>

Fortunato, L., & Galassi, M. (2021). The case for free and open source software in research and scholarship. *Philosophical Transactions of the Royal Society A*, 379(2197),

20200079. . <https://doi.org/10.1098/rsta.2020.0079>

Galbusera, F., & Cina, A. (2024). Image annotation and curation in radiology: An overview for machine learning practitioners. *European Radiology Experimental*, 8(11).

<https://link.springer.com/article/10.1186/s41747-023-00408-y>

González, R. C., & Woods, R. E. (2018). Digital image processing (4th ed.). *Pearson*.

<https://www.ci72.org/090imagePLib/books/Gonzales,Woods-Digital.Image.Processing.4th.Edition.pdf>

Greengard, S. (2021). The future of artificial intelligence in healthcare. *Communications of the ACM*, 64(4), 18–20.

https://www.researchgate.net/publication/383812398_The_Future_of_Artificial_Intelligence_in_Healthcare

Hernández-Sampieri, R., & Mendoza, C. (2018). Metodología de la investigación: Las rutas cuantitativa, cualitativa y mixta. *McGraw-Hill Education*. [https://artes.upn.edu.co/wp-content/uploads/2024/11/METODOLOGIA-DE-LA-INVESTIGACION-Sampieri-](https://artes.upn.edu.co/wp-content/uploads/2024/11/METODOLOGIA-DE-LA-INVESTIGACION-Sampieri-Mendoza-2018.pdf)

[Mendoza-2018.pdf](https://artes.upn.edu.co/wp-content/uploads/2024/11/METODOLOGIA-DE-LA-INVESTIGACION-Sampieri-Mendoza-2018.pdf)

Hosny, A., Parmar, C., Quackenbush, J., Schwartz, L. H., & Aerts, H. J. W. L. (2018).

Artificial intelligence in radiology. *Nature Reviews Cancer*, 18(8), 500–510.

<https://pubmed.ncbi.nlm.nih.gov/29777175/>

Inkinen, S. I., Kotiaho, A. O., Hanni, M., Nieminen, M. T., & Brix, M. A. K. (2024).

Computed tomography artefact detection using deep learning: Towards automated

quality assurance. En *Wireless and Digital Healthcare Solutions (Communications in Computer and Information Science, Springer*. pp. 17–28. https://doi.org/10.1007/978-3-031-59091-7_2

Kathiravelu, P., Sharma, P., Sharma, A., Banerjee, I., Trivedi, H., Purkayastha, S., Sinha, P., Cadrin-Chenevert, A., Safdar, N., & Gichoya, J. W. (2020). A DICOM framework for machine learning pipelines against real-time radiology images. *arXiv*.
<https://pubmed.ncbi.nlm.nih.gov/34405297/>

Kitchenham, B., & Charters, S. (2007). Guidelines for performing systematic literature reviews in software engineering. *Keele University*.
https://www.researchgate.net/publication/302924724_Guidelines_for_performing_Systematic_Literature_Reviews_in_Software_Engineering

Lawrence, R., Dodsworth, E., Massou, E., Sherlaw-Johnson, C., Ramsay, A. I. G., Walton, H., O'Regan, T., Gleeson, F., Crellin, N., Herbert, K., Ng, P. L., Elphinstone, H., Mehta, R., Lloyd, J., Halliday, A., Morris, S., & Fulop, N. J. (2025). Artificial intelligence for diagnostics in radiology practice: A rapid systematic scoping review. *EClinicalMedicine*, 83, 103228. <https://pubmed.ncbi.nlm.nih.gov/40474995/>

Lundström, C., & Lindvall, M. (2023). Mapping the landscape of care providers' quality assurance approaches for AI in diagnostic imaging. *Journal of Digital Imaging*, 36, 379–387. <https://link.springer.com/article/10.1007/s10278-022-00731-7>

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
<https://www.nature.com/articles/nature14539>

Mun, S. K., Wong, K. H., Lo, S. B., Li, Y. L., & Bayarsaikhan, S. (2021). Artificial intelligence for the future radiology diagnostic service. *Frontiers in Molecular*

Biosciences, 7, 614258. <https://www.frontiersin.org/journals/molecular-biosciences/articles/10.3389/fmolb.2020.614258/full>

- Pérez-Sanpablo, A. I., Quinzaños-Fresnedo, J., Gutiérrez-Martínez, J., Lozano-Rodríguez, I. G., & Roldan-Valadez, E. (2025). Transforming medical imaging: The role of artificial intelligence integration in PACS for enhanced diagnostic accuracy and workflow efficiency. *Current Medical Imaging*. <https://pubmed.ncbi.nlm.nih.gov/40265427>
- Pianykh, O. S. (2012). Digital imaging and communications in medicine (DICOM): A practical introduction and survival guide (2nd ed.). *Springer*. <https://download.e-bookshelf.de/download/0000/0124/25/L-G-0000012425-0002345932.pdf>
- Ridhi, S., Robert, D., Soren, P., Kumar, M., Pawar, S., & Reddy, B. (2024). Comparing the output of an artificial intelligence algorithm in detecting radiological signs of pulmonary tuberculosis in digital chest X-rays and smartphone-captured photos of X-ray films. *JMIR Formative Research*. <https://formative.jmir.org/2024/1/e55641>
- Seeram, E. (2019). Digital radiography: Physical principles and quality control (2nd ed.). *Springer*.
https://www.researchgate.net/publication/330603762_Digital_Radiography_Physical_Principles_and_Quality_Control
- Selles, M., van Osch, J. A. C., Maas, M., Boomsma, M. F., & Wellenberg, R. H. H. (2024). Advances in metal artifact reduction in CT images: A review of traditional and novel metal artifact reduction techniques. *European Journal of Radiology*, 170, 111276..
<https://doi.org/10.1016/j.ejrad.2023.111276>
- Shen, D., Wu, G., & Suk, H. I. (2017). Deep learning in medical image analysis. *Annual Review of Biomedical Engineering*, 19, 221–248.
<https://pubmed.ncbi.nlm.nih.gov/28301734/>

- Soltani, P., Devlin, H., Etemadi Sh, M., Rengo, C., Spagnuolo, G., & Baghaei, K. (2024). Do metal artifact reduction algorithms influence the detection of implant-related injuries to the inferior alveolar canal in CBCT images?. *BMC Oral Health*, *24*, 268.
<https://doi.org/10.1186/s12903-024-04043-w>
- Wajer, R., Wajer, A., Kazimierczak, N., Wilamowska, J., & Serafin, Z. (2024). The impact of AI on metal artifacts in CBCT oral cavity imaging. *Diagnostics*, *14*(12), 1280.
<https://doi.org/10.3390/diagnostics14121280>
- Wang, T., Xia, W., Huang, Y., Sun, H., Liu, Y., Chen, H., Zhou, J., & Zhang, Y. (2021). DAN-Net: Dual-domain adaptive-scaling non-local network for CT metal artifact reduction. *arXiv*. <https://arxiv.org/abs/2102.08003>
- Yilmaz, E. (2024). The importance and economic advantages of using national open source software in public institutions. *International Scientific and Vocational Studies Journal*, *8*(2), 202–210. <https://doi.org/10.47897/bilmes.1596600>