

Detección y corrección automática de artefactos en imágenes médicas utilizando redes neuronales para identificar y mejorar la precisión diagnóstica

Brayan Esteban Lozano

Hernán José Lambraño Celis

Mirley Patricia Sierra Díaz

Nikoll Fabiana Rincón Tarazona

Yojaira María Quiroz Pérez

Asesor

Alberto Guzmán Avilés

Universidad Nacional Abierta y a Distancia UNAD

Escuela de Ciencias de la Salud ECISA

Tecnología en Radiología e Imágenes Diagnósticas

2025

Agradecimientos

Agradecemos, en primer lugar, a Dios, por darnos la fortaleza, la claridad y la perseverancia necesarias para culminar este diplomado, permitiéndonos avanzar con sabiduría y determinación en cada etapa del proceso.

Expresamos también nuestro profundo agradecimiento a nuestras familias, por su apoyo incondicional, comprensión, motivación y por acompañarnos a lo largo de este camino, siendo nuestro sostén en los momentos de mayor exigencia.

Extendemos nuestro agradecimiento a la UNAD, por brindarnos un espacio académico de calidad, con acompañamiento y herramientas que hicieron posible nuestro crecimiento profesional y personal.

A nuestros tutores y docentes, quienes con su orientación, dedicación, paciencia y compromiso académico guiaron nuestro aprendizaje, motivándonos a desarrollar competencias que hoy fortalecen nuestro desempeño profesional.

Asimismo, extendemos nuestra gratitud a todas las personas que aportaron a la ejecución de este diplomado: compañeros, amigos, colaboradores y administrativo, quienes apoyaron a que este proceso fuera enriquecedor y significativo.

Finalmente, reconocemos el esfuerzo y compromiso de cada integrante de este grupo: Brayan Esteban Lozano, Hernán José Lambraño Celis, Mirley Patricia Sierra Díaz, Nikoll Fabiana Rincón Tarazona y Yojaira María Quiroz Pérez, quienes trabajamos de manera responsable y colaborativa para alcanzar el éxito propuesto, mostrando unidad, respeto y dedicación en cada actividad realizada.

Resumen

La calidad de las imágenes médicas es fundamental para obtener diagnósticos precisos, pero los artefactos y fallos técnicos continúan siendo un desafío, especialmente en instituciones con limitaciones tecnológicas. Ante esta problemática, las herramientas basadas en inteligencia artificial, en particular las redes neuronales convolucionales (CNNs), han demostrado gran potencial para mejorar imágenes, identificar artefactos y reducir errores diagnósticos al automatizar procesos de análisis. Esta investigación analiza la viabilidad, efectividad e impacto clínico de modelos basados en CNNs aplicados a estudios como la resonancia magnética. Se emplea una metodología mixta que combina un enfoque cuantitativo para evaluar métricas de precisión, sensibilidad y especificidad, y un enfoque cualitativo para revisar literatura, estudios de caso y experiencias de implementación. La evidencia indica que estas tecnologías pueden mejorar la calidad diagnóstica, disminuir la repetición de estudios e integrarse incluso en entornos con recursos limitados. No obstante, persisten retos como la capacitación del personal, la aceptación clínica, la interoperabilidad y la necesidad de estandarización. Los resultados esperados incluyen validar el desempeño de los modelos, identificar vacíos en el conocimiento y proponer recomendaciones prácticas para su integración ética y escalable en distintos entornos clínicos. En resumen, se busca aportar al desarrollo de herramientas accesibles que fortalezcan la eficiencia diagnóstica y promuevan mayor equidad en el acceso a tecnologías avanzadas.

Palabras Clave: inteligencia artificial, detección automática, aprendizaje profundo, redes neuronales convolucionales, deep learning.

Abstract

The quality of medical images is essential for achieving accurate diagnoses; however, artifacts and technical failures remain a significant challenge, particularly in institutions with limited technological resources. To address this issue, artificial intelligence tools, especially convolutional neural networks (CNNs), have shown strong potential to enhance image quality, identify artifacts, and reduce diagnostic errors by automating analysis processes. This research examines the viability, effectiveness, and clinical impact of CNN-based models applied to studies such as magnetic resonance imaging. A mixed-methods approach is employed, combining a quantitative evaluation of metrics such as accuracy, sensitivity, and specificity with a qualitative review of scientific literature, case studies, and implementation experiences. Evidence indicates that these technologies can improve diagnostic quality, reduce the need for repeat examinations, and integrate effectively even in resource-limited settings. Nonetheless, challenges remain, including staff training, clinical acceptance, interoperability with existing systems, and the need for technological standardization. The expected outcomes include validating model performance, identifying gaps in current knowledge, and proposing practical recommendations for their ethical and scalable integration into diverse clinical environments. Ultimately, this study aims to contribute to the development of accessible tools that enhance diagnostic efficiency and promote greater equity in access to advanced imaging technologies.

Keywords: artificial intelligence, automatic detection, deep learning, convolutional neural networks.

Tabla de Contenido

Introducción	10
Planteamiento del Problema	13
Justificación	15
Objetivos	19
Objetivo General.....	19
Objetivos Específicos	19
Marco Teórico.....	20
Inteligencia Artificial y Deep Learning en la Imagenología Médica	20
Redes Neuronales y su Aplicación en Imágenes Médicas	21
Corrección de Artefactos y Mejora de Calidad de Imagen	21
Aplicaciones Clínicas y Desarrollo de Herramientas Prácticas.....	22
La IA como Aliada en la Práctica Radiológica	22
Aprendizaje Profundo como Herramienta de Mejora Diagnóstica.....	23
Eficiencia y Transformación de los Entornos Radiológicos	23
Reconocimiento de Patrones en Imágenes Especializadas	23
Automatización de Procesos Críticos y Reducción De Errores	24
Reducción de Ruido y Artefactos sin Supervisión Humana.....	24
Integración en el Flujo Clínico Real.....	24
Fundamentos Técnicos y Viabilidad Clínica.....	25
Aplicaciones Avanzadas, Versatilidad De Uso e Integración Real.....	25
Viabilidad Clínica de la IA en Oncología y Otras Especialidades	27
Viabilidad Clínica en Contextos con Infraestructura Limitada	28

Desafíos y perspectivas	28
Aspectos Legales, Técnicos y Sostenibilidad a Largo Plazo.....	28
Marco Metodológico.....	30
Tipo de Investigación	30
Diseño de la Investigación.....	30
Tipo de Estudio.....	31
Enfoque Metodológico	31
Fuentes de Información	32
Criterios de Inclusión.....	32
Criterios de Exclusión	32
Parámetros Legales.....	33
Limitaciones del Estudio	33
Fases de Desarrollo de la Investigación	33
Fase 1. Definición del Problema, Revisión Teórica y Documental.....	33
Fase 2. Organización, Codificación y Sistematización de la Información.....	34
Fase 3. Análisis e Interpretación de Hallazgos	34
Fase 4. Propuesta De mejoras y Recomendaciones.....	34
Resultados.....	36
Propuesta de Mejoras Tecnológica, Organizacionales o de Capacitación para la Implementación Efectiva y Ética de Sistemas Automatizados en Centros de Salud con Capacidades Técnicas Reducidas	49
Mejoras Tecnológicas.....	49
Mejoras Organizacionales	50

Mejoras de Capacitación.....	50
Conclusiones.....	52
Referencias Bibliográficas	55

Lista de Tablas

Tabla 1 <i>Evaluación clínica de CNNs en la corrección de artefactos</i>	39
Tabla 2 <i>Factores tecnológicos y operativos que Limitan la Implementación de la IA en salud</i> .	41
Tabla 3 <i>Desafíos éticos y regulatorios en el uso de CNNs para imágenes médicas</i>	44
Tabla 4 <i>Propuesta para la implementación de IA en imágenes médicas</i>	47

Lista de Figuras

Figura 1 <i>Fases de la investigación</i>	35
--	----

Introducción

La calidad de las imágenes médicas es esencial para lograr diagnósticos precisos y decisiones terapéuticas adecuadas. Modalidades como la tomografía computarizada, la resonancia magnética y la radiografía son fundamentales en la práctica clínica, ya que permiten visualizar estructuras anatómicas, detectar patologías y apoyar la planificación, el seguimiento y el monitoreo de tratamientos. Sin embargo, la correcta interpretación de estas imágenes depende de su adecuada adquisición, siendo los artefactos uno de los principales problemas, pues pueden originarse por fallos técnicos, movimientos del paciente o limitaciones tecnológicas, generando distorsiones que afectan la representación real de las estructuras internas.

La aparición de estos artefactos deterioran la calidad diagnóstica de las imágenes médicas al afectar su nitidez y exactitud, lo que puede dificultar la detección de lesiones, generar errores diagnósticos y obligar a repetir estudios, aumentando costos, retrasos y, en algunos casos, la exposición a radiación. Este problema se agrava en entornos con recursos limitados, donde la falta de tecnología avanzada y personal especializado reduce la calidad y equidad en la atención médica. Frente a este desafío, los avances en inteligencia artificial, especialmente el aprendizaje profundo y las redes neuronales convolucionales, han transformado el análisis de imágenes médicas al permitir una detección y optimización más precisa y eficiente, comparable o superior a la de especialistas humanos en ciertas tareas.

Las redes neuronales convolucionales (CNNs) destacan en tareas como la clasificación, segmentación, reconstrucción y realce de imágenes médicas, gracias a su capacidad de aprender automáticamente patrones complejos sin intervención manual. Esta ventaja es clave en el ámbito médico, donde la variabilidad anatómica y el ruido limitan los métodos tradicionales. Una de sus aplicaciones más importantes es la detección y corrección automática de artefactos, ya que

pueden identificar y clasificar distorsiones de forma precisa y aplicar correcciones que mejoran significativamente la calidad y fiabilidad diagnóstica de las imágenes.

El impacto de estas tecnologías va más allá de la simple mejora visual de las imágenes. Su integración tiene el potencial de transformar la dinámica de trabajo en radiología y otras especialidades, al permitir la estandarización de procedimientos, la reducción de errores humanos, la disminución de la carga laboral y la optimización del uso de los recursos disponibles. A medida que la IA continúa evolucionando, se abren nuevas posibilidades para la creación de sistemas inteligentes capaces de aprender de manera continua, adaptarse a diferentes contextos clínicos y resolver problemas complejos con una autonomía cada vez mayor.

A pesar del potencial clínico de los sistemas automatizados basados en inteligencia artificial, su implementación efectiva depende de la existencia de una infraestructura tecnológica robusta y confiable. Estos sistemas requieren hardware de alto rendimiento capaz de procesar grandes volúmenes de datos en tiempo real, conectividad estable que permita la transmisión segura de imágenes y resultados, software especializado para el entrenamiento y la ejecución de modelos de aprendizaje profundo, así como redes de datos confiables que garanticen la integridad, confidencialidad y disponibilidad de la información médica. Sin la presencia de estos elementos, incluso los algoritmos más avanzados no pueden desplegar su máximo rendimiento ni ofrecer resultados clínicamente útiles.

En muchos hospitales, especialmente en zonas rurales o con recursos limitados, la falta de infraestructura tecnológica, equipos obsoletos, escasa interoperabilidad y capacitación insuficiente del personal dificultan la integración de soluciones basadas en inteligencia artificial. Estas barreras generan una brecha entre los avances científicos y su aplicación clínica real. Superarlas requiere no solo inversión en tecnología, sino también capacitación, estandarización

de sistemas, mejora de la conectividad y políticas de salud digital que permitan una adopción sostenible, mejorando así la calidad diagnóstica, la eficiencia clínica y la equidad en la atención médica.

Ante este panorama, es necesario realizar investigaciones rigurosas sobre la viabilidad y efectividad de las CNNs para la detección y corrección de artefactos en imágenes médicas, evaluando tanto su desempeño técnico como su integración en entornos clínicos con limitaciones. A partir de este análisis, pueden desarrollarse estrategias para un uso responsable, ético y escalable de estas tecnologías, que incluyan mejoras en infraestructura, capacitación, interoperabilidad, validación continua y políticas que aseguren un acceso equitativo a soluciones avanzadas.

La investigación busca demostrar la viabilidad de integrar modelos basados en CNNs en instituciones de salud con recursos limitados, evidenciando su aporte a la mejora de la calidad de las imágenes médicas, la precisión diagnóstica y la confiabilidad clínica. Su importancia radica en un enfoque integral que considera aspectos tecnológicos, organizativos, éticos y de equidad, destacando el potencial de la inteligencia artificial para reducir desigualdades en el acceso a diagnósticos avanzados y promover una atención médica más eficiente, justa y centrada en el paciente.

Planteamiento del Problema

La evolución tecnológica en salud ha permitido desarrollar sistemas automatizados de análisis e interpretación de imágenes diagnósticas, capaces de identificar patologías y artefactos con alta precisión. Sin embargo, en muchos entornos clínicos, la implementación de estos sistemas se ve limitada por la deficiente infraestructura tecnológica. Esta situación genera una gran diferencia entre los avances científicos y su aplicabilidad real en el sistema de salud.

Desde el punto de vista clínico, la falta de tecnología adecuada impacta directa y negativamente en la calidad del diagnóstico. Los artefactos en las imágenes médicas, como distorsiones o interferencias, se traducen en errores de interpretación visual, llevando a diagnósticos erróneos o tratamientos inadecuados. Sistemas automatizados basados en IA podrían detectar y corregir estos artefactos, pero su instalación requiere de un hardware avanzado, una conectividad robusta y un procesamiento en tiempo real, capacidades que no están disponibles en muchas instituciones de salud (Panayides et al., 2020).

Asimismo, Caicedo et al., (2024) señalan que los centros hospitalarios a nivel operativo tienen sobrecarga de trabajo debido al poco personal; la automatización mediante IA podría ser la solución para aliviar significativamente esta carga, procesando grandes volúmenes de imágenes en menos tiempo. No obstante, la carencia de equipos modernos, redes seguras y software especializado impide adoptar estos sistemas en su totalidad.

Desde la perspectiva de equidad y acceso, la distribución desigual de infraestructura médica entre áreas urbanas y rurales amplifica la brecha sanitaria. En Colombia, por ejemplo, se ha documentado que los equipos de tomografía computarizada se concentran en ciudades principales, mientras que municipios pequeños carecen incluso de conectividad adecuada para

acceder a servicios de teleradiología, tal como refiere Camargo (2024), esta situación excluye a muchas comunidades del acceso a herramientas diagnósticas modernas.

Desde el enfoque técnico y académico, la falta de interoperabilidad entre sistemas, la ausencia de estándares tecnológicos, y la escasa capacitación del personal en herramientas digitales, dificultan aún más la integración de sistemas automatizados en los flujos de trabajo clínicos. Incluso cuando existen intenciones de modernización, las limitaciones estructurales impiden el despliegue efectivo de soluciones de IA en imágenes médicas (Elhanashi et al., 2025).

En la innovación tecnológica, existen alternativas emergentes como el Internet de las Cosas (IoT), la computación en la nube y la teleradiología, que pueden brindar soluciones ante la infraestructura limitada. No obstante, su implementación también depende de inversiones en conectividad, seguridad de datos y políticas sanitarias orientadas hacia la transformación digital. Sin embargo, como subraya Chandy (2019), estas soluciones, aunque prometedoras, aún no son accesibles para muchos centros de salud debido a restricciones presupuestarias y normativas.

La falta de infraestructura tecnológica es un obstáculo técnico y una barrera estructural para mejorar el acceso, la calidad y la equidad en los servicios de salud. Superar este reto requiere una visión multidisciplinaria que incluya inversión pública, formación profesional, innovación tecnológica y políticas de salud digital integrales.

Con este análisis se plantea la pregunta problema: ¿Cómo influye la limitada infraestructura tecnológica en la implementación eficiente y efectiva de sistemas automatizados de detección de artefactos en imágenes médicas, y qué mejoras específicas se requieren para superar estas barreras en el contexto de instituciones de salud con recursos tecnológicos restringidos?

Justificación

El propósito de esta investigación es analizar cómo la implementación de redes neuronales para la detección y corrección automática de artefactos en imágenes médicas contribuye a mejorar la precisión diagnóstica. Se busca identificar los factores que afectan la calidad de las imágenes, evaluar el impacto de estas herramientas en la reducción de errores interpretativos y en la optimización del flujo diagnóstico, así como disminuir la exposición innecesaria del paciente a radiación al evitar repeticiones de estudios. Además, la investigación pretende aportar al conocimiento actual en imagenología médica mediante una revisión crítica de los avances recientes en inteligencia artificial y las oportunidades que las redes neuronales ofrecen para automatizar y optimizar los procesos de diagnóstico.

La necesidad de optimizar el diagnóstico médico ha impulsado el desarrollo de tecnologías automatizadas basadas en IA para el análisis de imágenes médicas. Sin embargo, su implementación depende de la disponibilidad de infraestructura tecnológica adecuada, algo que muchas instituciones de salud aún no poseen. Este desfase entre el avance científico y la capacidad operativa de los centros médicos plantea una serie de retos clínicos, operativos, sociales y técnicos que deben abordarse de forma integral.

La precisión diagnóstica es un pilar esencial en la atención médica, ya que permite detectar enfermedades en etapas tempranas, iniciar tratamientos adecuados y evitar errores que puedan comprometer la salud del paciente. En este sentido, los sistemas automatizados con IA representan un avance clave, ya que pueden identificar patrones sutiles en imágenes que podrían pasar desapercibidos en una evaluación humana, especialmente bajo condiciones de fatiga o presión de tiempo.

Según Caicedo et al., (2024), la IA aplicada a imágenes médicas puede reducir la variabilidad diagnóstica, al estandarizar la interpretación de imágenes y eliminar errores humanos. Esto es particularmente valioso en la detección de patologías como cáncer, enfermedades cardiovasculares o lesiones neurológicas.

No obstante, sin la infraestructura tecnológica adecuada, como servidores de alto rendimiento, redes de datos rápidas y almacenamiento seguro, estas tecnologías no pueden ser implementadas de manera efectiva, por eso surge la necesidad de cerrar esta brecha tecnológica para potenciar la calidad clínica del diagnóstico médico.

En muchos centros hospitalarios, los servicios de radiología enfrentan una alta demanda y limitaciones en el personal técnico especializado, lo cual retrasa los diagnósticos y puede comprometer la atención oportuna. En este contexto, la automatización mediante herramientas de inteligencia artificial representa una solución efectiva para optimizar el flujo de trabajo.

Los sistemas automatizados pueden procesar grandes volúmenes de imágenes en menor tiempo, detectar anomalías con rapidez y priorizar estudios críticos para revisión humana. Esta eficiencia es crucial en emergencias o unidades de cuidados intensivos, donde los tiempos de respuesta son vitales. Caicedo et al., (2024) destacan que la IA no busca reemplazar al personal médico, sino apoyarlo, liberándolo de tareas repetitivas y permitiendo enfocarse en casos complejos. Sin embargo, esta automatización solo es posible si se dispone de plataformas tecnológicas modernas, software especializado y una infraestructura de soporte robusta. En muchos entornos, especialmente rurales o con bajo presupuesto, estas condiciones no existen, lo que limita el aprovechamiento de estas herramientas de mejora operativa.

La limitada infraestructura tecnológica no solo representa un obstáculo técnico, sino también una fuente de inequidad en el acceso a servicios diagnósticos avanzados. En países

como Colombia, los equipos de diagnóstico por imagen, como la tomografía computarizada (TAC) y la resonancia magnética, están desigualmente distribuidos, con una alta concentración en grandes centros urbanos y una escasa disponibilidad en regiones rurales o de difícil acceso. Camargo (2024) explica que esta disparidad genera una desventaja para la población que vive en zonas apartadas, ya que deben desplazarse largas distancias para acceder a exámenes especializados y que se ven excluidos del beneficio de tecnologías automatizadas que podrían mejorar la calidad del diagnóstico.

Mejorar la infraestructura tecnológica en estas áreas no solo permitiría implementar sistemas automáticos de detección de artefactos, sino que también democratizaría el acceso a servicios médicos de calidad, ayudando a reducir las brechas de inequidad sanitaria en el país.

A pesar del potencial que ofrecen los sistemas automatizados en la medicina, su implementación práctica enfrenta varios desafíos técnicos y logísticos. Entre ellos se destacan la interoperabilidad entre dispositivos, la calidad de las imágenes adquiridas, la necesidad de software específico compatible con los estándares clínicos, y la falta de personal capacitado en el uso de tecnologías digitales avanzadas.

No obstante, a pesar del potencial que ofrecen los sistemas automatizados en la medicina, su implementación práctica enfrenta varios desafíos técnicos y logísticos. Entre ellos se destacan la interoperabilidad entre dispositivos, la calidad de las imágenes adquiridas, la necesidad de software específico compatible con los estándares clínicos, y la falta de personal capacitado en el uso de tecnologías digitales avanzadas.

A este respecto, Panayides et al., (2020) subrayan que una de las barreras más críticas es la dificultad para integrar los sistemas de IA dentro de los flujos de trabajo clínicos existentes. Esto se debe, en parte, a que muchas instituciones aún trabajan con equipos antiguos que no

permiten la integración con nuevas tecnologías. Además, la infraestructura de red, los sistemas de respaldo y la seguridad informática son fundamentales para garantizar el funcionamiento estable y seguro de estos sistemas, asimismo, señalan que la automatización puede mejorar la detección de artefactos, lo que evita diagnósticos erróneos causados por imágenes distorsionadas y si no se superan estos retos técnicos, los beneficios de la automatización en imágenes médicas seguirán siendo inaccesibles para la mayoría de instituciones, perpetuando la dependencia de procesos manuales menos precisos y más lentos.

Frente a la limitada infraestructura tecnológica, algunas soluciones emergentes pueden servir como alternativas viables para la implementación de sistemas automatizados, entre ellas las tecnologías ALoT, la teleradiología, la computación en la nube y los sistemas de diagnóstico remoto. Estas herramientas permiten procesar imágenes fuera del centro médico en cuestión, superando limitaciones locales de hardware o personal especializado. Chandy (2019) analiza cómo el uso del IoT en imágenes médicas mejora la eficiencia del monitoreo y diagnóstico a distancia, facilitando la colaboración entre especialistas desde diferentes ubicaciones.

Del mismo modo, plataformas en la nube pueden almacenar y analizar imágenes médicas con sistemas automatizados sin necesidad de infraestructura compleja en el sitio de adquisición. No obstante, la implementación de estas soluciones también requiere conectividad estable, regulación sobre protección de datos, y políticas institucionales que favorezcan la digitalización. Aunque no reemplazan la necesidad de infraestructura física moderna, estas tecnologías emergentes ofrecen una vía complementaria y escalable para avanzar en la automatización diagnóstica en contextos con recursos limitados.

Objetivos

Objetivo General

Analizar la viabilidad técnica, clínica y operativa de los sistemas automatizados basados en redes neuronales convolucionales (CNNs) para la detección y corrección de artefactos en imágenes médicas, con especial énfasis en su implementación en instituciones de salud con infraestructura tecnológica limitada.

Objetivos Específicos

Identificar los fundamentos teóricos y técnicos de las redes neuronales convolucionales (CNNs) aplicadas a la mejora de la calidad de las imágenes médicas, con énfasis en su capacidad para detectar y corregir artefactos derivados de fallos técnicos, movimiento del paciente o condiciones inadecuadas de adquisición.

Evaluar el desempeño y aplicabilidad clínica de modelos existentes basados en CNNs para la detección y corrección automática de artefactos, utilizando métricas objetivas y considerando su adaptabilidad a contextos con recursos tecnológicos limitados.

Identificar los factores tecnológicos, operativos, legales y estructurales que dificultan la adopción de estas tecnologías en instituciones de salud con infraestructura restringida, a partir del análisis de literatura científica, estudios de caso y experiencias documentadas.

Proponer estrategias y recomendaciones tecnológicas, organizacionales y de capacitación, fundamentadas en la evidencia obtenida de la revisión bibliográfica, que faciliten la integración efectiva, ética y sostenible de sistemas automatizados basados en CNNs en centros de salud con capacidades técnicas limitadas.

Marco Teórico

Inteligencia Artificial y Deep Learning en la Imagenología Médica

La evolución de la IA y el Deep learning ha transformado el campo de diagnóstico por imágenes, donde la tecnología emergente permite automatizar tareas complejas como la detección de artefactos, mejora de calidad de imagen y apoyo al diagnóstico, aumentando la eficiencia y precisión de los procesos clínicos.

La IA emerge como una herramienta importante en el campo de la imagenología médica, permitiendo automatizar procesos que requerían intervención humana especializada, su aplicación va desde el reconocimiento de patrones hasta la detección temprana de enfermedades, reducción de artefactos y priorización de hallazgos críticos.

Asimismo, la presencia de artefactos es un desafío significativo para la precisión diagnóstica, estos errores pueden ser ocasionados por el movimiento del paciente, fallos del equipo o condiciones técnicas desfavorables, lo cual afecta la calidad de las imágenes y, por ende, la interpretación médica. Ante esta problemática, el desarrollo de sistemas automáticos basados en redes neuronales, especialmente las redes neuronales convolucionales (CNN), ha demostrado ser una solución efectiva para la detección y corrección automática de artefactos, optimizando así los procesos clínicos y reduciendo la carga sobre los radiólogos.

Sin embargo, hay factores como el movimiento del paciente, errores en la adquisición o limitaciones técnicas del equipo que pueden introducir artefactos que comprometen la interpretación. La corrección de estos defectos ha dependido de la intervención humana, lo cual no siempre es viable, en entornos con pocos especialistas o alto volumen de estudios, es ahí donde entran las redes neuronales profundas como una solución tecnológica eficiente y

accesible. Estas redes permiten detectar y corregir artefactos de manera automática, optimizando la calidad de las imágenes sin necesidad de supervisión constante.

La creciente integración de sistemas de IA en entornos clínicos demuestra no solo su potencial técnico, sino también su viabilidad práctica y operativa en la mejora del diagnóstico por imágenes. Para comprender este tema, se desglosa de la siguiente forma:

Redes Neuronales y su Aplicación en Imágenes Médicas

Las redes neuronales, especialmente las convolucionales, CNNs, han demostrado un potencial notable en la clasificación, segmentación y mejora de imágenes médicas. Según Sarmiento (2020), las redes neuronales permiten abordar tareas tradicionalmente complejas en la ingeniería biomédica, incluyendo la interpretación automatizada de imágenes médicas, lo que abre un amplio espectro de aplicaciones clínicas con un gran impacto en el diagnóstico y la toma de decisiones médicas.

Este enfoque también ha sido revisado detalladamente por Latif et al., (2019), quienes exponen cómo los algoritmos de aprendizaje profundo permiten realizar un análisis más eficiente y preciso de las imágenes médicas, gracias a su capacidad para detectar patrones complejos no evidentes para los especialistas.

Corrección de Artefactos y Mejora de Calidad de Imagen

Uno de los principales desafíos en la adquisición de imágenes médicas es la presencia de artefactos, los cuales pueden interferir con el diagnóstico. Para abordar este problema, Chen et al., (2023) presentan una revisión sobre el uso de técnicas de aprendizaje profundo para la mejora y corrección de imágenes en resonancia magnética. Este análisis evidencia cómo las redes neuronales son capaces de identificar y corregir distorsiones de manera automatizada, mejorando así la utilidad diagnóstica de las imágenes.

En línea con lo anterior, Gil et al., (2023) muestran la eficacia de un sistema automático basado en IA para la detección de artefactos en señales neuronales, proponiendo una adaptación para el análisis de imágenes médicas, donde se destaca la precisión del sistema y también su aplicabilidad clínica en diagnóstico neurológico, lo cual refuerza la viabilidad de estas herramientas en entornos reales.

Aplicaciones Clínicas y Desarrollo de Herramientas Prácticas

La implementación clínica de estas tecnologías debe ser práctica, a este respecto, Ezhov et al., (2021) desarrollaron un sistema de IA aplicable al diagnóstico dental a través de imágenes CBCT, mostrando cómo estas soluciones pueden integrarse exitosamente en flujos de trabajo médicos existentes, mejorando la precisión y velocidad del diagnóstico odontológico.

Asimismo, García (2023) demuestra cómo las redes neuronales pueden ser implementadas para el desarrollo de aplicaciones para la detección de imágenes médicas. Su trabajo enseña que la implementación de soluciones accesibles basadas en IA puede extender el uso clínico de estas herramientas más allá de los centros altamente especializados.

La IA como Aliada en la Práctica Radiológica

La IA no va a reemplazar a los radiólogos, va a funcionar de forma colaborativa y complementaria, en este sentido, Gampala et al., (2020) argumentan que la IA se ha convertido en una aliada diagnóstica valiosa, al facilitar la interpretación de imágenes complejas, reducir el tiempo de análisis y mejorar la precisión diagnóstica, sin desplazar el juicio clínico humano

Esta visión se refuerza con los hallazgos de Lee y Summers (2021), quienes destacan la implementación clínica de la IA en el análisis de imágenes torácicas y abdominales, especialmente útil en regiones con escasez de radiólogos, permitiendo mejorar la cobertura diagnóstica en poblaciones vulnerables.

Aprendizaje Profundo como Herramienta de Mejora Diagnóstica

El aprendizaje profundo (Deep learning) ha revolucionado el análisis de imágenes al permitir la segmentación, clasificación y mejora de imagen con altos niveles de precisión. Según McBee et al., (2018), estas herramientas automatizadas ya se integran en flujos clínicos reales, incluso en instituciones con recursos limitados, demostrando su potencial para mejorar la precisión diagnóstica al identificar irregularidades, como los artefactos.

De esta forma, Wani y Reshi (2023) argumentan que los avances recientes en IA han superado muchas barreras humanas y técnicas, permitiendo una detección de artefactos más rápida y menos dependiente del juicio humano, siendo útil en salas con carga diagnóstica elevada y disponibilidad limitada de radiólogos.

Eficiencia y Transformación de los Entornos Radiológicos

La IA no solo mejora la calidad de imagen o detecta artefactos; también está transformando completamente los flujos de trabajo en áreas como la radiología, Bhandari (2024) señala que la integración de sistemas automáticos inteligentes puede mejorar significativamente la eficiencia diagnóstica, reduciendo el tiempo de lectura de imágenes, minimizando errores humanos y permitiendo una atención más oportuna.

Reconocimiento de Patrones en Imágenes Especializadas

La capacidad de la IA para detectar patrones en imágenes musculoesqueléticas, cardíacas o cerebrales ha sido validada por diversos estudios, Gorelik et al., (2020) exponen cómo los algoritmos de reconocimiento de patrones han sido exitosamente aplicados en imágenes musculoesqueléticas, permitiendo identificar anomalías de forma más rápida y confiable.

Por su parte, Chukwujindu et al., (2024) examinan el papel de la IA en la obtención de imágenes de tumores cerebrales, destacando su utilidad en entornos diagnósticos complejos

donde la presencia de artefactos y la necesidad de precisión son críticas. Esto demuestra que los sistemas automáticos son efectivos incluso en escenarios de alta complejidad clínica.

Automatización de Procesos Críticos y Reducción De Errores

Uno de los avances más significativos de la IA ha sido la automatización de procesos clínicos de alto impacto, Prevedello et al., (2017) muestran que, al detectar y notificar automáticamente hallazgos críticos en imágenes médicas, se mejoran los tiempos de respuesta, especialmente en entornos hospitalarios con recursos humanos limitados.

En cuanto a cardiología, Lanzafame et al., (2023) demostraron cómo la IA puede reducir artefactos en imágenes de tomografía computarizada y resonancia magnética, lo que contribuye a diagnósticos más precisos y confiables en una de las especialidades médicas más demandantes en términos de imagenología.

Reducción de Ruido y Artefactos sin Supervisión Humana

Uno de los desafíos en el entrenamiento de redes neuronales es la necesidad de grandes volúmenes de datos etiquetados. Sin embargo, Cui et al., (2019) han demostrado que es posible aplicar aprendizaje profundo no supervisado para eliminar ruido en imágenes médicas, lo que es valioso en centros donde no se dispone de suficientes expertos.

De forma similar, Hashimoto et al., (2019) presentan una técnica de reducción de ruido en imágenes PET que no requiere datos previos ni supervisión, validando la viabilidad de implementar sistemas automáticos de mejora de imagen incluso cuando la información clínica histórica es limitada.

Integración en el Flujo Clínico Real

La incorporación de estas herramientas en entornos clínicos reales requiere que los sistemas automáticos sean compatibles con los flujos de trabajo existentes, Kapoor et al., (2020)

abordan este aspecto al analizar cómo se integran las herramientas de IA en el proceso clínico radiológico, desde la adquisición de imágenes hasta la validación diagnóstica. Señalan que una IA capaz de detectar artefactos automáticamente mejora no solo la calidad de imagen, sino también la eficiencia operativa del servicio radiológico.

Esta integración también ha sido destacada por la European Society of Radiology (2019), que considera a la IA como un elemento clave en la transformación sostenible de la radiología moderna. La detección automatizada de artefactos representa una solución concreta ante la escasez de personal en muchos centros hospitalarios, permitiendo que los recursos humanos se enfoquen en tareas clínicas más críticas.

Fundamentos Técnicos y Viabilidad Clínica

Las redes neuronales convolucionales han sido utilizadas en el análisis de imágenes médicas debido a su capacidad para identificar patrones complejos y corregir anomalías visuales. Salehi et al., (2023) explican cómo las CNN y el aprendizaje por transferencia permiten desarrollar sistemas automáticos eficientes para la mejora de imágenes, incluso en condiciones con recursos tecnológicos limitados. Este enfoque refuerza su viabilidad clínica, al adaptarse a diferentes contextos hospitalarios y mantener la precisión diagnóstica.

De igual manera, Liu et al., (2021) demuestran cómo la IA aplicada a imágenes PET permite reducir el ruido y los artefactos, mejorando la calidad de imagen sin tener que repetir estudios, lo que permite reducir costos, además de proteger al paciente de exposiciones innecesarias, por repeticiones de estudios.

Aplicaciones Avanzadas, Versatilidad De Uso e Integración Real

La versatilidad de las redes neuronales también se ha reflejado en áreas más complejas de la imagenología médica, Glielmo et al., (2024) describen el papel de la IA en radiología

intervencionista, donde se requiere precisión extrema. La detección automática de artefactos en este contexto es crucial para evitar errores durante procedimientos guiados por imagen, reforzando la seguridad del paciente y la efectividad del tratamiento. Estos sistemas también son útiles como apoyo al radiólogo, al alertar sobre imágenes defectuosas o fuera de parámetros, lo que permite su corrección inmediata, esta función es crítica en centros de radiología con alto volumen de pacientes, donde el error humano o el descuido por sobrecarga de trabajo pueden ser más frecuentes.

Entonces, la literatura revisada demuestra que la detección automática de artefactos mediante redes neuronales es factible, viable y necesaria en la imagenología médica. Su integración en flujos de trabajo reales, su adaptabilidad a entornos con recursos limitados y su validación en condiciones normativas y operativas confirman que estos sistemas son una solución práctica para la calidad de la imagen diagnóstica. Las redes neuronales permiten mejorar esta calidad de forma automática, reduciendo errores, optimizando recursos y aumentando la confianza clínica en los diagnósticos basados en imagen.

Varios autores muestran que los sistemas automáticos de corrección de imagen son una realidad tecnológica en curso. Rong et al., (2019) hacen un análisis integral de las aplicaciones de IA en salud, destacando su utilidad en la reducción de errores diagnósticos y la disminución de la dependencia del personal altamente capacitado, lo que es una ventaja en regiones con escasez de especialistas. entonces, la detección automática de artefactos con redes neuronales profundas es una solución efectiva y una estrategia viable y sostenible para mejorar la calidad diagnóstica en centros con limitaciones estructurales, logísticas o de personal.

En síntesis, la literatura revisada demuestra que la detección automática de artefactos mediante redes neuronales es una solución factible, viable y necesaria en la imagenología médica

actual, que su integración en flujos de trabajo reales, su adaptabilidad a entornos con recursos limitados y su validación bajo condiciones normativas y operativas confirman que estos sistemas son una solución práctica para optimizar la calidad de la imagen diagnóstica. Las redes neuronales permiten mejorar esta calidad de forma automática, reduciendo errores, optimizando recursos y aumentando la confianza clínica en los diagnósticos basados en imagen.

Viabilidad Clínica de la IA en Oncología y Otras Especialidades

La integración de sistemas de IA en el diagnóstico oncológico está generando mejoras en los resultados clínicos, Tripathi et al., (2024) revisan cómo la IA ha sido utilizada en el análisis de imágenes de cáncer de páncreas, mejorando no solo la detección temprana, sino también la predicción de resultados clínicos. Este enfoque es particularmente relevante en escenarios donde los recursos médicos son limitados, lo que demuestra la escalabilidad y aplicabilidad de estas herramientas.

La evidencia actual indica que la inteligencia artificial ha dejado de ser una promesa futura para convertirse en una realidad operativa en el diagnóstico por imágenes, desde la detección automatizada de artefactos y patrones complejos hasta la priorización de hallazgos críticos, la IA está transformando profundamente la práctica radiológica y otras especialidades médicas. Su implementación clínica ha sido documentada en contextos diversos, incluyendo imágenes musculoesqueléticas, neurológicas, cardiovasculares, torácicas y oncológicas. La viabilidad técnica, clínica y operativa de estos sistemas ha sido ampliamente demostrada, aunque aún persisten desafíos éticos, regulatorios y de interpretación que deben ser abordados en futuros desarrollos e investigaciones.

Viabilidad Clínica en Contextos con Infraestructura Limitada

La adopción de tecnologías basadas en IA no debe restringirse a grandes centros hospitalarios. Najjar (2023) muestra cómo estas soluciones pueden adaptarse incluso a instituciones con infraestructura básica.

Por su parte, Zhang y Sejdic (2019) abordan las barreras tecnológicas que dificultan la integración de redes neuronales profundas en la práctica médica, pero también demuestran cómo pueden superarse con el uso estratégico del aprendizaje automático, con herramientas sostenibles, adaptables y escalables para mejorar la calidad de las imágenes.

Desafíos y perspectivas

A pesar de los avances, aún existen desafíos técnicos, éticos y regulatorios en la implementación clínica de la IA. Es esencial que los desarrollos tecnológicos mantengan altos estándares de seguridad, precisión y explicabilidad para su validación y aceptación por parte de la comunidad médica. Chen et al., (2023) y Sarmiento (2020) coinciden en que, si bien el potencial es alto, la integración plena de estas tecnologías requiere superar barreras como la disponibilidad de grandes volúmenes de datos anotados, la interoperabilidad de los sistemas y la confianza de los profesionales de la salud.

Aspectos Legales, Técnicos y Sostenibilidad a Largo Plazo

La aplicación clínica de estas tecnologías debe estar acompañada por marcos normativos adecuados, Scott y De Cecco (2020) ofrecen una visión integral de los aspectos técnicos y legales involucrados en la implementación de IA en radiología, donde señalan que para que un sistema de detección automática de artefactos sea clínicamente viable, debe cumplir con estándares regulatorios, asegurar la trazabilidad de las decisiones automáticas y garantizar la seguridad del paciente.

Además, Patil y Panchal (2023) demuestran cómo la IA ha sido implementada de forma exitosa incluso en países con poca infraestructura médica, esto resalta la escalabilidad y adaptabilidad de estas soluciones automáticas, que pueden ser empleadas en hospitales pequeños, rurales o en desarrollo, siempre que se garantice la capacitación del personal médico y la interoperabilidad con los sistemas existentes.

Marco Metodológico

Tipo de Investigación

La presente investigación es de tipo cualitativo, descriptivo y documental analítico, con un enfoque exploratorio, analítico y propositivo. Su propósito es comprender, interpretar y analizar cómo la limitada infraestructura tecnológica influye en la implementación de sistemas automatizados basados en redes neuronales para la detección y corrección de artefactos en imágenes médicas. Se busca identificar barreras técnicas, operativas y estructurales, así como proponer soluciones adaptables a contextos clínicos con recursos restringidos.

Según Hernández et al., (2022), este tipo de investigación cualitativa permite explorar fenómenos complejos dentro de contextos específicos, generando comprensión profunda más que medición cuantitativa. Este enfoque resulta pertinente para abordar problemáticas tecnológicas emergentes en el campo de la inteligencia artificial aplicada a la imagenología médica.

Además, la revisión integrativa, como lo plantean Whitemore y Knafl (2005) y Snyder (2019), permite incluir múltiples tipos de evidencia cuantitativa, cualitativa y técnica para construir una visión comprehensiva sobre tecnologías emergentes en salud.

Diseño de la Investigación

El diseño adoptado es no experimental y de corte transversal, ya que no se manipulan variables, sino que se recolecta y analiza información existente para interpretar la realidad observada. A través de la revisión crítica de literatura especializada, estudios de caso, y experiencias documentadas, se construirá una visión integral del estado actual de estas tecnologías en contextos con limitaciones técnicas.

En las investigaciones no experimentales, los fenómenos se estudian tal como ocurren en su contexto natural, sin intervención directa del investigador (Hernández et al., 2022).

Tipo de Estudio

Se trata de una revisión integrativa de literatura científica, orientada a sistematizar el conocimiento existente sobre el uso de redes neuronales, particularmente convolucionales (CNN), en la detección automática de artefactos en imágenes médicas. Este tipo de estudio resulta especialmente útil en áreas en constante evolución, como la inteligencia artificial en el ámbito clínico, permitiendo evaluar avances, identificar brechas de conocimiento y proponer líneas futuras de investigación.

Siguiendo la perspectiva de Torracó (2016) y Snyder (2019), este tipo de revisión implica recopilar, categorizar, analizar e interpretar de manera crítica literatura relevante, incluyendo estudios empíricos, revisiones sistemáticas, ensayos teóricos y documentos técnicos pertinentes al fenómeno estudiado.

Enfoque Metodológico

El enfoque cualitativo permitirá realizar un análisis comprensivo y contextualizado de los desafíos tecnológicos, operativos y estructurales que dificultan la implementación de sistemas de IA en la imagenología médica. Además, la identificación de modelos exitosos y propuestas de mejora aplicables a instituciones con recursos limitados. Creswell y Poth (2018) destacan que el enfoque cualitativo es idóneo para explorar fenómenos complejos desde una perspectiva comprensiva y contextualizada, especialmente cuando se busca generar recomendaciones prácticas.

Este enfoque facilita el análisis profundo de los desafíos asociados a la implementación de inteligencia artificial en instituciones con infraestructura limitada, así como la identificación

de modelos exitosos y la formulación de propuestas prácticas, éticas y escalables para su integración efectiva en el entorno clínico.

Fuentes de Información

La información fue recolectada mediante una búsqueda sistemática en bases de datos académicas y científicas especializadas, tales como: PubMed, ScienceDirect, Scopus, Biblioteca virtual Unad, Google Académico, SpringerLink, Researchgate, entre otros.

Se incluyeron publicaciones en español e inglés, comprendidas entre los años 2010 y 2025, relacionadas con el uso de redes neuronales para la detección automática de artefactos en imágenes médicas, considerando tanto su aplicación clínica como su viabilidad técnica en entornos de baja capacidad tecnológica.

Criterios de Inclusión

Estudios centrados en el uso de redes neuronales convolucionales (CNN) y técnicas de aprendizaje profundo (deep learning).

Investigaciones aplicadas en entornos clínicos reales o en simulaciones clínicas realistas.

Publicaciones que discutan la implementación en contextos con infraestructura tecnológica limitada.

Artículos que aborden la detección y/o corrección automática de artefactos en imágenes médicas.

Criterios de Exclusión

Estudios que no aborden la temática de artefactos diagnósticos o que se enfoquen en otras áreas de la imagenología médica sin relación con el problema investigado.

Parámetros Legales

Esta investigación se basa en revisión bibliográfica de artículos científicos y literarios, se asegura la veracidad de la información presentada, garantizando la citación de todas las fuentes consultadas, en cumplimiento con las normas de la APA, 7.^a edición.

Limitaciones del Estudio

Por ser una revisión documental, depende de la disponibilidad y calidad de la literatura publicada entre 2010 y 2025, lo que puede dejar vacíos sobre investigaciones recientes o contextos de bajos recursos. La heterogeneidad de los estudios revisados, en términos de metodologías, modelos de redes neuronales, tipos de artefactos y métricas de evaluación, dificulta la comparación directa y la generalización de los resultados.

Fases de Desarrollo de la Investigación

El desarrollo de esta investigación se organizó en cinco fases secuenciales, basadas en los lineamientos metodológicos propuestos por Torracco (2016) para revisiones integrativas, combinadas con un enfoque analítico adaptado al estudio de tecnologías emergentes en salud. Estas fases permitieron garantizar un abordaje sistemático, riguroso y contextualizado del fenómeno investigado: el uso de redes neuronales convolucionales (CNN) para la detección y corrección automática de artefactos en imágenes médicas en contextos clínicos con infraestructura limitada.

Fase 1. Definición del Problema, Revisión Teórica y Documental

Definición del objetivo del estudio y la pregunta de investigación.

Revisión sistemática de literatura científica sobre el uso de IA y redes neuronales en la corrección de artefactos, en bases de datos académicas especializadas, tales como PubMed, Scopus, ScienceDirect, SpringerLink, Google Académico, Biblioteca Virtual UNAD y

ResearchGate, empleando combinaciones de palabras clave como: inteligencia artificial, redes neuronales, artefactos en imágenes médicas, diagnóstico automático, entre otras y criterios de inclusión abarcando publicaciones en inglés y español entre los años 2013 y 2025.

Análisis de estudios de caso en instituciones con y sin limitaciones tecnológicas.

Fase 2. Organización, Codificación y Sistematización de la Información

Categorización de la información según variables como: factores técnicos, económicos y operativos que obstaculizan la implementación de estas tecnologías, condiciones necesarias para su adopción efectiva, modalidad de imagen, artefactos, tipo de red neuronal y aplicabilidad.

Análisis de herramientas y modelos de IA documentados en literatura académica.

Valoración de su rendimiento técnico, requerimientos de hardware/software, y escalabilidad.

Fase 3. Análisis e Interpretación de Hallazgos

Análisis temático categorizado en ejes como: efectividad técnica de los modelos, barreras de implementación, desafíos éticos y legales, adaptabilidad a diferentes contextos institucionales y sostenibilidad de las soluciones propuestas.

Síntesis crítica de los hallazgos en términos de aplicabilidad, escalabilidad y validación clínica de las soluciones automatizadas basadas en redes neuronales.

Fase 4. Propuesta De mejoras y Recomendaciones

Elaboración de un conjunto de estrategias adaptables para instituciones con infraestructura tecnológica limitada y sugerencias de políticas, capacitación y estándares mínimos para facilitar su implementación.

Figura 1*Fases de la investigación**Nota.* Autoría propia

Resultados

En la presente investigación literaria, titulada “Detección automática de artefactos utilizando redes neuronales: uso de redes neuronales para identificar y corregir automáticamente artefactos en imágenes médicas, mejorando la precisión diagnóstica”, se identificaron las principales causas que afectan la calidad de las imágenes médicas, evidenciando cómo los artefactos generados durante la adquisición del estudio comprometen la idoneidad de las imágenes para la interpretación diagnóstica y cómo las redes neuronales ofrecen soluciones automáticas para su corrección.

Las redes neuronales convolucionales (CNNs) destacan en la mejora de imágenes médicas gracias a su capacidad para aprender características jerárquicas. Las capas iniciales identifican patrones simples, como bordes o texturas, mientras que las capas profundas capturan relaciones complejas entre estructuras anatómicas, lo que permite diferenciar información real del paciente frente a artefactos generados por movimiento, ruido o errores técnicos. Este enfoque jerárquico es la base de modelos como U-Net y ResNet, que consistentemente alcanzan precisiones superiores al 90 % en tareas de corrección de imágenes médicas.

El modelo U-Net se destaca particularmente en la reconstrucción de imágenes con artefactos de movimiento, como los generados por movimientos involuntarios del paciente durante una resonancia magnética. Su arquitectura de encoder-decoder con conexiones de salto permite que las capas profundas recuperen información contextual mientras preservan detalles locales importantes. Esto explica por qué, según Chen et al., (2023), una U-Net modificada puede lograr hasta un 93 % de precisión en la reconstrucción de imágenes afectadas por movimiento, manteniendo la integridad de estructuras anatómicas críticas.

Por otro lado, ResNet, especialmente cuando se combina con técnicas de detección como YOLOv8, es altamente efectiva frente a artefactos múltiples y complejos que afectan distintas modalidades de imagen simultáneamente. La profundidad de ResNet y sus conexiones residuales permiten un aprendizaje más estable de características profundas sin degradación de la señal, lo que resulta en un F1-score del 95 % según Elhanashi et al., (2025). Esto es especialmente útil en entornos donde las imágenes presentan ruido, distorsión por movimiento y artefactos técnicos combinados.

Los autoencoders no supervisados son eficaces para corregir ruido en imágenes PET, ya que aprenden representaciones latentes de la imagen sin necesidad de datos etiquetados, logrando reducciones de ruido de hasta el 45 %. Su fuerza radica en la capacidad de reconstruir la imagen a partir de una versión comprimida y filtrada, eliminando información no relevante mientras preservan características anatómicas esenciales (Cui et al., 2019).

Finalmente, para entornos con limitaciones computacionales, las arquitecturas ligeras como MobileNet y EfficientNet permiten mantener precisiones altas, 91 % en la reducción de artefactos digitales según Salehi et al., (2023) mediante el uso de convoluciones profundas separables, cuantización de parámetros y diseños eficientes de capa. Esto las hace ideales para implementaciones clínicas donde los recursos de hardware son limitados, sin sacrificar la calidad de la reconstrucción de la imagen.

El análisis de los resultados evidencia que las CNNs tienen una alta capacidad para detectar y corregir artefactos en distintas modalidades de imágenes médicas, incluyendo TC, RM y PET. Se observa que arquitecturas como U-Net y ResNet sobresalen por su habilidad para aprender características jerárquicas profundas y distinguir entre estructuras anatómicas reales y ruido. Para corregir artefactos de movimiento, la U-Net resulta especialmente efectiva debido a

su capacidad de reconstrucción detallada y preservación de información anatómica; frente a artefactos múltiples o complejos, la combinación de ResNet con técnicas avanzadas como YOLOv8 y transfer learning permite abordar distorsiones simultáneas con alta precisión.

Para la reducción de ruido en situaciones donde no se dispone de datos etiquetados, los autoencoders no supervisados filtran información irrelevante mientras mantienen las estructuras anatómicas esenciales. Por otro lado, los modelos optimizados como MobileNet o EfficientNet permiten mantener altos niveles de exactitud en entornos con recursos computacionales limitados, demostrando que la elección de la arquitectura depende tanto del tipo de artefacto como de las condiciones de implementación.

En conjunto, estas estructuras representan un equilibrio entre precisión, capacidad de aprendizaje jerárquico y eficiencia computacional, confirmando su aplicabilidad adaptativa según las necesidades clínicas y tecnológicas.

Los modelos basados en CNNs han demostrado un impacto significativo en la mejora de la calidad de las imágenes médicas y en la reducción de errores diagnósticos. Según Liu et al. (2021), la aplicación de CNN convolucional profunda en imágenes PET permitió reducir el ruido estructural en un 50 %, mejorando la legibilidad y precisión diagnóstica en equipos de PET modernos con detectores de alta resolución. De manera similar, Najjar (2023) reporta que el uso de CNN con aprendizaje por transferencia en resonancia magnética (RM) disminuye en un 35 % la necesidad de repetir exámenes, especialmente en RM de 3 Tesla, donde los artefactos de movimiento suelen ser más prominentes debido a la mayor sensibilidad de estos equipos.

Tabla 1*Evaluación clínica de CNNs en la corrección de artefactos*

Autor / Año	Modalidad de Imagen	Artefacto Corregido	Modelo CNN Aplicado	Resultados	Conclusión
Liu et al., 2021	PET	Ruido estructural	CNN convolucional profunda	Reducción del 50% del ruido	Mejora la calidad de reconstrucción y legibilidad de las imágenes.
Najjar, 2023	RM	Artefactos de movimiento	CNN + aprendizaje por transferencia	Reducción del 35% de exámenes repetidos	Mejora la precisión diagnóstica y reduce costos.
Chen et al., 2023	RM	Distorsiones de campo	U-Net modificada	93% de detección de artefactos	Demuestra alta efectividad clínica.
García, 2023	TC	Artefactos técnicos	CNN híbrida	85% de exactitud	Valida el uso clínico en entornos reales.

Nota. Autoría propia

La Tabla evidencia que arquitecturas como U-Net modificada en RM (Chen et al., 2023) logran detectar artefactos con un 93 % de precisión, destacándose en escáneres de campo alto, mientras que modelos híbridos de CNN aplicados a TC (García, 2023) alcanzan un 85 % de exactitud, especialmente efectivos en equipos con protocolos de adquisición estándar y software de reconstrucción avanzado. En conjunto, estos resultados reflejan que la eficacia clínica de las CNNs puede variar dependiendo del tipo de equipo, la modalidad de imagen y la calidad de los datos de entrenamiento.

Además, la evidencia comparativa indica que U-Net y GANs médicas no solo mejoran resolución, contraste y reducción de ruido, sino que también son capaces de operar de manera adaptable en entornos con infraestructura limitada, manteniendo un rendimiento clínico aceptable, lo que resalta que la selección de la arquitectura debe ajustarse al equipo disponible,

tipo de artefacto y modalidad de imagen, optimizando la relación entre precisión diagnóstica y recursos hospitalarios.

Este análisis respalda que las CNNs constituyen una herramienta clínica viable y efectiva, capaz de mejorar la calidad de las imágenes médicas y reducir errores diagnósticos, siempre que se acompañen de validación continua, ajustes técnicos específicos para cada equipo y entrenamiento con datasets representativos para garantizar su aplicabilidad y precisión en contextos clínicos diversos.

Asimismo, el éxito de la implementación de IA médica depende de factores operativos, estructurales y humanos que determinan su aplicabilidad en entornos clínicos reales, como la interoperabilidad de los sistemas, la capacidad técnica del personal y la disponibilidad de recursos computacionales son componentes críticos que pueden favorecer o limitar el rendimiento de las soluciones basadas en IA.

Panayides et al., (2020) señalan que la falta de estandarización entre los sistemas de almacenamiento de imágenes (PACS/RIS) es una de las principales barreras para la integración eficiente de herramientas inteligentes en los flujos de trabajo hospitalarios. Esta carencia de compatibilidad entre plataformas impide el intercambio fluido de datos y retrasa la automatización de procesos como la detección de artefactos o la optimización de parámetros de imagen.

De igual forma, Camargo (2024) resalta que solo el 32 % de las instituciones públicas de salud en Colombia cuenta con equipos compatibles con sistemas de IA, como brecha tecnológica significativa en América Latina. Esta realidad limita la posibilidad de aplicar algoritmos de aprendizaje profundo de manera rutinaria en radiología digital, obstaculizando los beneficios potenciales en precisión diagnóstica y eficiencia operativa, entonces, se hace indispensable

fortalecer las capacidades técnicas del talento humano, con capacitación continua, soporte técnico y alfabetización digital.

Además, la creación de políticas públicas que impulsen la estandarización de los sistemas de información y la inversión tecnológica se presenta como una prioridad para garantizar que los avances en inteligencia artificial beneficien de manera equitativa tanto a instituciones de alta complejidad como a hospitales regionales o rurales.

Tabla 2

Factores tecnológicos y operativos que Limitan la Implementación de la IA en salud

Factor Identificado	Problema	Impacto Operativo	Posible Solución	Autor
Infraestructura insuficiente	Equipos sin GPU ni servidores IA	Bajo rendimiento de los modelos	Uso de modelos livianos (MobileNet)	Salehi et al., (2023)
Falta de interoperabilidad	Sistemas PACS/RIS no compatibles	Pérdida de eficiencia diagnóstica	Protocolos DICOM estandarizados	Panayides et al., (2020)
Escasa capacitación	Personal no entrenado en IA médica	Baja adopción tecnológica	Programas de formación continua	Creswell y Poth (2018)
Limitación de conectividad	Internet inestable o insuficiente	Dificulta actualización de modelos	Uso de IA local sin conexión constante	Rong et al., (2019)

Nota. Autoría propia

La tabla muestra que la adopción de CNNs en instituciones con infraestructura limitada se ve obstaculizada por factores como:

Tecnológicos: limitaciones de hardware y capacidad de almacenamiento que afectan la ejecución de modelos complejos y la dependencia de software especializado que requiere actualizaciones constantes y personal capacitado.

Operativos: falta de protocolos estandarizados y necesidad de tiempo y personal capacitado.

Legales: la responsabilidad y normativas de privacidad que pueden ser difíciles de implementar en entornos con infraestructura limitada.

Estructurales: la resistencia al cambio por parte del personal médico y técnico y la escasa inversión en capacitación y actualización tecnológica.

En conjunto, se evidencia que, aunque las CNNs ofrecen mejoras significativas en la calidad de imágenes médicas y optimizan la eficiencia diagnóstica, su adopción requiere superar barreras multidimensionales, lo que subraya la necesidad de estrategias de implementación cuidadosamente adaptadas a contextos de recursos limitados. Más allá de los desafíos técnicos, la aplicación de CNNs en imágenes médicas plantea importantes consideraciones éticas relacionadas con la privacidad, la transparencia algorítmica y la responsabilidad profesional en la toma de decisiones médicas asistidas por inteligencia artificial.

Estos desafíos pueden analizarse principalmente en tres dimensiones: la protección de la privacidad de los datos clínicos, la transparencia y explicabilidad de los algoritmos utilizados, y la responsabilidad profesional en la interpretación y aplicación de los resultados generados por la IA. Scott y De Cecco (2020) destacan que los radiólogos deben mantener una supervisión activa sobre el proceso diagnóstico, evitando depender completamente de los algoritmos. La naturaleza de caja negra de muchas redes neuronales profundas dificulta rastrear y justificar las decisiones clínicas, lo que genera preocupación sobre la capacidad de detectar sesgos en los modelos o justificar recomendaciones diagnósticas ante casos complejos.

Asimismo, la European Society of Radiology (2019) recomienda la implementación de comités éticos tecnológicos y el estricto cumplimiento de estándares de anonimización y manejo

seguro de datos clínicos. En entornos con infraestructura limitada, la aplicación de estos principios requiere adaptación, asegurando que las medidas de ética y seguridad no comprometan la calidad del cuidado ni la integridad de la información.

Por lo tanto, la implementación ética de la IA en radiología demanda un equilibrio entre innovación tecnológica y responsabilidad profesional. Para lograr un uso responsable de las CNNs, es esencial garantizar transparencia en los algoritmos, ofrecer capacitación continua al personal médico, mantener supervisión humana sobre las decisiones automatizadas y establecer protocolos claros de trazabilidad y rendición de cuentas. De esta manera, la inteligencia artificial puede integrarse de forma segura y efectiva, fortaleciendo la calidad diagnóstica y la confianza en los sistemas automatizados, incluso en entornos con limitaciones tecnológicas.

Tabla 3*Desafíos éticos y regulatorios en el uso de CNNs para imágenes médicas*

Aspecto	Problema	Consecuencia	Solución	Fuente	Aplicación	Impacto / Artefactos	Requisitos
Privacidad de datos	Riesgo de exposición de información sensible	Violación de normas de protección	Aplicar técnicas de anonimización	ESR (2019)	RM, TC, PET: anonimización de estudios antes de entrenar CNNs	Permite entrenar modelos sin comprometer información de imagen	Herramientas de anonimización, protocolos de manejo seguro de datos
Sesgo algorítmico	Entrenamiento con datos no representativos	Diagnósticos erróneos	Diversificar datasets de entrenamiento	Rong et al., (2019)	Ultrasonido y RM: asegurar diversidad en edad, género y patologías	Mejora la precisión en la detección de artefactos	Bases de datos diversas, almacenamiento y etiquetado estandarizado
Responsabilidad profesional	Confusión sobre decisiones automáticas	Riesgos legales	Supervisión humana obligatoria	Scott y De Cecco (2020)	TC y PET: revisión por radiólogos antes de diagnóstico final	Garantiza que la corrección de artefactos sea validada y confiable	Integración de sistemas de revisión, formación de personal
Falta de regulación local	Ausencia de normas específicas	Dificultad de validación	Crear marcos regulatorios nacionales	ESR (2019)	Todas las modalidades: establecer estándares nacionales de validación para CNNs	Establece criterios claros para evaluar la efectividad de CNNs en mejora de imágenes	Protocolos estandarizados, auditorías regulatorias

Nota. Autoría propia

La tabla muestra cómo diferentes aspectos éticos y legales afectan la implementación de redes neuronales convolucionales (CNNs) en imágenes médicas. Cada fila relaciona un problema detectado con sus posibles consecuencias, las soluciones recomendadas y su impacto práctico en la clínica y en la calidad de imagen. En privacidad de datos en el uso de CNNs para imágenes médicas es un aspecto crítico, ya que la exposición de información sensible de los pacientes puede violar normas de protección y generar riesgos legales significativos. Para mitigar este problema, se recomienda aplicar técnicas de anonimización, lo que permite que los datos sean utilizados para entrenar los modelos sin comprometer la identidad o información confidencial de los pacientes. De esta manera, se asegura que la integridad de las imágenes médicas se mantenga, garantizando al mismo tiempo la confiabilidad y seguridad de los sistemas automatizados en entornos clínicos.

El sesgo algorítmico surge cuando las CNNs se entrenan con datos no representativos, lo que puede dar diagnósticos erróneos y disminuir la confiabilidad del modelo. Para contrarrestarlo, es fundamental diversificar los datasets de entrenamiento, lo que permite a las redes neuronales detectar y corregir artefactos en imágenes médicas de diferentes poblaciones y condiciones clínicas. Por su parte, la responsabilidad profesional se ve afectada por la automatización, ya que puede generar confusión sobre quién responde por las decisiones, aumentando los riesgos legales; la solución es mantener supervisión humana obligatoria, garantizando que la corrección de artefactos e interpretación de imágenes sea confiable y validada por especialistas. Finalmente, la falta de regulación local representa un obstáculo para la implementación de CNNs en la práctica clínica, debido a la ausencia de normas específicas; desarrollar marcos regulatorios nacionales establece estándares claros para evaluar y certificar la efectividad de estos sistemas, asegurando consistencia en la corrección de artefactos y en la

calidad de las imágenes médicas. Entonces, a partir del análisis de la literatura, de autores como Bhandari, 2024; Gampala et al., 2020; Najjar, 2023, se plantea la necesidad de un enfoque estratégico, progresivo y colaborativo para la implementación de sistemas de IA en instituciones de salud con recursos limitados. Este enfoque contempla varias líneas de acción complementarias orientadas a fortalecer la infraestructura, la capacitación del personal y la sostenibilidad operativa:

Adopción de modelos open source y herramientas accesibles: permite reducir costos y aumentar la adaptabilidad de las soluciones, facilitando su personalización según las necesidades locales y la disponibilidad de datos.

Alianzas con universidades y centros de investigación: fomentar la colaboración académica permite la capacitación de personal, el acceso a datasets de calidad y la creación de proyectos piloto que validen la eficacia de los modelos antes de su escalamiento clínico.

Infraestructura compartida: establecimiento de nodos de procesamiento centralizados y laboratorios conjuntos puede disminuir los costos de adquisición de hardware y software, haciendo más viable la implementación de redes neuronales convolucionales (CNNs) para la mejora de imágenes médicas.

Uso de aprendizaje federado: esta técnica permite entrenar modelos de IA de manera colaborativa sin compartir directamente datos sensibles de pacientes, reforzando la seguridad y cumpliendo con las normativas de privacidad. Además, promueve la cooperación interinstitucional, mejorando la representatividad de los datos y reduciendo sesgos algorítmicos.

Capacitación continua y actualización tecnológica: la formación de equipos multidisciplinarios (médicos, ingenieros y técnicos) asegura que las soluciones de IA sean interpretables, confiables y éticamente aplicables, garantizando su sostenibilidad a largo plazo.

Optimización específica para imágenes diagnósticas médicas: implementar protocolos de entrenamiento y validación de CNNs orientados a la corrección de artefactos en diferentes modalidades de imágenes médicas (resonancia, TAC, rayos X), asegurando la calidad y precisión diagnóstica incluso en entornos con equipos o condiciones subóptimas.

Este enfoque busca la eficiencia económica y técnica, pero también la integración ética y sostenible de la IA en la práctica clínica, permitiendo que instituciones con limitaciones de recursos puedan acceder a tecnologías avanzadas sin comprometer la seguridad, la calidad de los diagnósticos y la equidad en la atención médica.

Tabla 4

Propuesta para la implementación de IA en imágenes médicas

Línea de Acción	Descripción	Beneficio/Impacto	Fuente
Adopción de modelos open source	Uso de herramientas accesibles y personalizables	Reducción de costos, mayor adaptabilidad	Bhandari, 2024
Alianzas con universidades y centros de investigación	Colaboración académica para capacitación y validación de modelos	Acceso a datasets de calidad, formación de personal y proyectos piloto confiables	Gampala et al., 2020
Infraestructura compartida	Creación de nodos de procesamiento centralizados y laboratorios conjuntos	Disminución de costos de hardware/software, viabilidad de CNNs para imágenes médicas	Najjar, 2023
Uso de aprendizaje federado	Entrenamiento de modelos sin compartir datos sensibles	Seguridad de datos, reducción de sesgo algorítmico, colaboración interinstitucional	Bhandari, 2024
Capacitación continua y actualización tecnológica	Formación de equipos multidisciplinarios en IA y diagnóstico médico	Interpretabilidad, confiabilidad y sostenibilidad de los sistemas	Gampala et al., 2020
Optimización específica para imágenes diagnósticas	Protocolos de entrenamiento y validación de CNNs para corrección de artefactos en TAC, resonancia y rayos X	Mejora de la calidad y precisión diagnóstica, incluso con recursos limitados	Najjar, 2023

Nota. Autoría propia

El enfoque estratégico propuesto busca implementar la IA en instituciones con recursos limitados de manera ética, sostenible y efectiva. La adopción de modelos open source y la creación de infraestructura compartida reducen costos, mientras que las alianzas con universidades permiten acceder a datasets de calidad y formar personal capacitado. El aprendizaje federado garantiza la seguridad de los datos y la colaboración interinstitucional sin comprometer la privacidad de los pacientes. Además, la capacitación continua del personal asegura la interpretabilidad y confiabilidad de los modelos.

Finalmente, la optimización específica de CNNs para la corrección de artefactos en imágenes diagnósticas (TAC, resonancia y rayos X) mejora significativamente la calidad y precisión clínica, permitiendo que estas tecnologías sean útiles y adaptables incluso en contextos con recursos limitados.

Propuesta de Mejoras Tecnológica, Organizacionales o de Capacitación para la Implementación Efectiva y Ética de Sistemas Automatizados en Centros de Salud con Capacidades Técnicas Reducidas

Con base en la evidencia revisada sobre inteligencia artificial aplicada a la imagenología médica (Bhandari, 2024; Chen et al., 2023; Scott y De Cecco, 2020; European Society of Radiology, 2019; Snyder, 2019), se proponen mejoras tecnológicas, organizacionales y de capacitación para facilitar la implementación ética, efectiva y escalable de sistemas automatizados de detección y corrección de artefactos en centros de salud con infraestructura técnica limitada:

Mejoras Tecnológicas

Es fundamental adoptar redes neuronales convolucionales (CNNs) optimizadas para entornos con recursos computacionales limitados, priorizando algoritmos que sean eficientes, escalables y de bajo requerimiento de hardware, de modo que puedan implementarse incluso en centros de salud con infraestructura modesta (Lanzafame et al., 2023; Salehi et al., 2023).

Esto incluye el uso de técnicas de compresión de modelos, reducción de parámetros y aprendizaje por transferencia, que permiten mantener un alto desempeño sin la necesidad de servidores o GPUs de alto rendimiento. Además, se recomienda la integración de sistemas de IA interoperables con los equipos médicos existentes y plataformas de gestión de imágenes, garantizando compatibilidad con formatos DICOM y sistemas PACS, para facilitar la automatización del flujo de trabajo clínico.

La implementación de soluciones modulares y escalables permitirá que los centros de salud puedan adaptar progresivamente la tecnología, incorporando actualizaciones de software y mejoras de algoritmos sin interrumpir la operación clínica. Finalmente, es esencial incluir

herramientas de monitoreo en tiempo real que evalúen el desempeño del sistema, detecten errores de procesamiento y aseguren la calidad de las imágenes generadas, promoviendo así una adopción confiable y sostenible de la inteligencia artificial en el diagnóstico por imágenes.

Mejoras Organizacionales

Es esencial establecer protocolos claros y estandarizados que definan la supervisión humana de los resultados generados por sistemas de IA, garantizando trazabilidad, responsabilidad clínica y la capacidad de intervenir ante posibles errores diagnósticos (Scott y De Cecco, 2020).

Se recomienda la creación de comités de ética tecnológica que supervisen el uso de la inteligencia artificial en la práctica clínica, velando por la privacidad y seguridad de los datos de los pacientes, así como por la transparencia y explicabilidad de los algoritmos empleados (European Society of Radiology, 2019).

Además, estos comités pueden definir lineamientos para la validación periódica de los modelos de IA, asegurando su desempeño confiable y evitando sesgos en los resultados. La estandarización de flujos de trabajo, junto con la definición de roles y responsabilidades claras para el personal clínico y técnico, permitirá integrar los sistemas automatizados de manera ética y segura en los procesos diagnósticos, promoviendo una cultura organizacional orientada a la innovación responsable y a la mejora continua en centros de salud con recursos limitados.

Mejoras de Capacitación

Capacitar al personal radiólogos y técnicos en radiología en el uso, interpretación y limitaciones de los sistemas automatizados de inteligencia artificial es fundamental para garantizar una integración segura y efectiva (Creswell y Poth, 2018; Wani y Reshi, 2023).

Esta formación debe incluir talleres prácticos, simulaciones y guías operativas adaptadas a las capacidades técnicas del centro de salud, con énfasis en la identificación de artefactos, validación de resultados generados por IA y manejo adecuado de las imágenes médicas. Además, es crucial fomentar una cultura de colaboración entre los profesionales de la radiología y los sistemas de IA, donde la tecnología sea una herramienta complementaria que apoye la toma de decisiones clínicas, pero no sustituya la supervisión humana.

Estas estrategias no solo buscan optimizar la calidad de las imágenes y mejorar la precisión diagnóstica, sino también promover un uso responsable, ético y sostenible de la inteligencia artificial en radiología, especialmente en entornos con recursos limitados, asegurando que la innovación tecnológica se traduzca en mejores resultados clínicos y seguridad del paciente.

Conclusiones

Las CNNs poseen estructuras especializadas que les permiten detectar patrones complejos en imágenes médicas, haciéndolas altamente eficaces en la identificación y corrección de artefactos. Arquitecturas como U-Net y ResNet sobresalen por su capacidad de aprender características jerárquicas profundas y distinguir entre estructuras anatómicas reales y ruido, lo que se traduce en reconstrucciones precisas en distintas modalidades, incluyendo TC, RM y PET.

La elección de la arquitectura y los parámetros adecuados depende del tipo de artefacto y de las condiciones del entorno clínico. La U-Net es ideal para artefactos de movimiento, ResNet para artefactos múltiples o complejos, Autoencoders no supervisados para reducción de ruido sin datos etiquetados, y modelos optimizados como MobileNet o EfficientNet permiten mantener alta precisión en entornos con recursos computacionales limitados. Esta selección estratégica maximiza la exactitud y confiabilidad de los modelos.

A pesar de la robustez de estas técnicas, el entrenamiento efectivo de las CNNs requiere datasets representativos y balanceados. La calidad y diversidad de los datos son determinantes para minimizar errores y sesgos, garantizar la generalización del modelo y asegurar que las mejoras en la imagen sean consistentes y aplicables en entornos clínicos reales. La combinación de arquitecturas adecuadas con datos de alta calidad constituye la base para lograr reconstrucciones adaptativas y precisas.

La efectividad de los modelos depende directamente de métricas objetivas como PSNR y SSIM, que permiten comparar rendimiento y establecer estándares de calidad.

Los modelos CNN muestran mejoras significativas en la corrección automática de artefactos, reduciendo el tiempo de revisión manual y mejorando la confiabilidad de los diagnósticos.

Los estudios indican que la aplicabilidad clínica de las CNNs es prometedora, pero su implementación requiere ajustes según la disponibilidad tecnológica de cada centro médico.

La adopción de CNNs en instituciones con recursos limitados se ve afectada por barreras tecnológicas, falta de capacitación del personal y carencias de infraestructura.

Obstáculos legales y regulatorios representan riesgos potenciales para la implementación segura y confiable de estas tecnologías.

Superar estas barreras exige un enfoque integral que combine formación profesional, políticas claras y estrategias de adaptación tecnológica.

Las CNNs han demostrado una alta capacidad para detectar y corregir artefactos en distintas modalidades de imágenes médicas (TC, RM y PET), mejorando la calidad diagnóstica y reduciendo la repetición de exámenes. Arquitecturas como U-Net y ResNet destacan por su habilidad para aprender características jerárquicas profundas, mientras que modelos optimizados como MobileNet o EfficientNet mantienen una buena precisión. La implementación de estas estructuras, seleccionadas según el tipo de artefacto y los recursos del entorno clínico, contribuye a optimizar la interpretación médica, reducir costos y aumentar la eficiencia del flujo de trabajo hospitalario.

La privacidad de los datos es un elemento crítico en la adopción de CNNs en entornos clínicos. Mejorar la gestión de las *habeas data*, el derecho a la protección y control de los datos personales, fortalece la seguridad y confianza del sistema, garantizando que el uso de inteligencia artificial respete los derechos del paciente. La aplicación de técnicas de anonimización y encriptación permite entrenar modelos sin comprometer la identidad ni la información sensible, asegurando el cumplimiento de normas éticas y legales. Como señala Osuna (2024), la protección de los datos personales en Colombia se sustenta en el artículo 15 de

la Constitución Política, que reconoce el derecho de toda persona a conocer, actualizar y rectificar la información que sobre ella se haya recogido. En consecuencia, la aplicación de técnicas de anonimización y encriptación en el entrenamiento de CNN permite procesar información clínica sin comprometer la identidad ni los datos sensibles del paciente, cumpliendo con las normas éticas, legales y de confidencialidad que rigen la práctica médica.

A pesar del avance de las CNNs, la supervisión humana sigue siendo indispensable para garantizar la responsabilidad profesional, la precisión diagnóstica y la confiabilidad de la interpretación de imágenes. La intervención del especialista valida los resultados y corrige posibles errores, mientras que la creación de marcos regulatorios locales establece estándares éticos técnicos que promueven la transparencia, seguridad y correcta integración de la IA en la práctica médica.

El aprendizaje federado permite entrenar CNNs para imágenes médicas de manera segura, protegiendo la información sensible de los pacientes. La adopción de modelos open source y la infraestructura compartida reduce costos y facilita la implementación de IA en instituciones con recursos limitados y la optimización de CNNs para la corrección de artefactos en imágenes diagnósticas aumenta la calidad clínica de las imágenes, promoviendo una aplicación ética, confiable y escalable.

Referencias Bibliográficas

- Bhandari, A. (2024). Revolucionando la radiología con inteligencia artificial. *Cureus*, 16(2), e72646. <https://doi.org/10.7759/cureus.72646>
- Caicedo, A., Caraballo, I., Rodríguez, N., Barrios, R., & Mendoza, Y. (2024). *Inteligencia artificial en la interpretación de imágenes médicas*. [Trabajo de grado, Universidad Nacional Abierta y a Distancia - UNAD]. Repositorio UNAD. <https://repository.unad.edu.co/bitstream/handle/10596/64852/ipcaraballo.pdf?isAllowed=y&sequence=1>
- Camargo, J. (2024). Aproximación a la capacidad instalada de equipos de tomografía computarizada en Colombia. *Revista CIFE: Lecturas De Economía Social*, 26(44), 8-42. <https://doi.org/10.15332/22484914.10545>
- Chandy, A. (2019). A review on iot based medical imaging technology for healthcare applications. *Journal of Innovative Image Processing*, 1(1), 51-60. <https://www.researchgate.net/publication/337897017>
- Chen, Z., Pawar, K., Ekanayake, M., Pain, C., Zhong, S., & Egan, G. (2023). Aprendizaje profundo para la mejora y corrección de imágenes en resonancia magnética: estado del arte y desafíos. *Journal of Digital Imaging*, 36(2), 478–495. <https://doi.org/10.1007/s10278-022-00721-9>
- Chukwujindu, E., Faiz, H., Al-Douri, S., Faiz, K. & De Sequeira, A. (2024). El papel de la inteligencia artificial en la obtención de imágenes de tumores cerebrales. *European Journal of Radiology*, 172, 111509. <https://doi.org/10.1016/j.ejrad.2024.111509>
- Cortés, K., & Mejía, M. (2017). *Estado del arte y elementos del reconocimiento automático de imágenes del cerebro*. Centro Nacional de Investigación y Desarrollo Tecnológico.

https://rcs.cic.ipn.mx/2017_140/Estado%20del%20arte%20y%20elementos%20del%20reconocimiento%20automatico%20de%20imagenes%20del%20cerebro.pdf

Creswell, J., & Poth, C. (2018). *Qualitative inquiry and research design: Choosing among five approaches (4th ed.)*. SAGE Publications.

https://spada.uns.ac.id/pluginfile.php/510378/mod_resource/content/1/creswell.pdf

Cui, J., Gong, K., Guo, N., WU, C., Menga, X., Kim, K., Zheng, K, Wu, Z, Fu, L., Xu, B., Zhu, Z., Tian, J., Lui, H. & Li, Q. (2019). Eliminación de ruido de imágenes PET mediante aprendizaje profundo no supervisado. *Springer Nature (46)*, 2780-2789.

<https://doi.org/10.1007/s00259-019-04468-4>

Elhanashi, A., Saponara, S., Zheng, Q., Almutairi, N., Singh, Y., Kuanar, S., Ali, F., Unal, O. & Faghani, S. (2025). Detección de objetos con IA en radiología: Modelos actuales, desafíos y futuro. *Journal of Imaging* , 11 (5), 141.

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

European Society of Radiology (ESR). (2019). *What the radiologist should know about artificial intelligence - an ESR white paper*. <https://doi.org/10.1186/s13244-019-0738-2>

Ezhov, M., Arzhevitin, O., Golitsyna, M., Kiselev, A. & Tamimi, I. (2021). Sistema de inteligencia artificial clínicamente aplicable para el diagnóstico dental con CBCT.

Scientific Reports, 11, 19638. <https://doi.org/10.1038/s41598-021-94093-9>

Gampala, S., Vankeshwara, V. & Siva, S. (2020). ¿Es la inteligencia artificial la nueva aliada de los radiólogos? *Cureus*, 12(7), e11137. <https://doi.org/10.7759/cureus.11137>

García, I. (2023). *Desarrollo de aplicación basada en redes neuronales para detectar imágenes médicas*. [Trabajo de grado, Universidad de Sevilla]. Biblos Universidad de Sevilla.

<https://biblus.us.es/bibing/proyectos/abreproy/94501/fichero/TFG-4501+Garc%C3%ADa+Mayorga.pdf>

Geirhos, R., Medina Temme, C. R., Rauber, J., Schütt, H. H., Bethge, M., & Wichmann, F. A. (2018b). Generalisation in humans and deep neural networks. *Proceedings of the 32nd Conference on Neural Information Processing Systems (NeurIPS)*, Montréal, Canadá.

<https://arxiv.org/abs/1808.08750>

Gil, A., Pérez, S., Rodríguez, V., Hoshi, H., Shigihara, Y., Gómez, C., & Poza, J. (2023).

Detector automático de artefactos en señales neuronales basado en técnicas de Inteligencia Artificial. <http://hdl.handle.net/10317/13735>

Glielmo, P., Fusco, S., Gitto, S., Zantonelli, G., Albano, D., Messina, C., Sconfienza, L. &

Mauri, G. (2024). Inteligencia artificial en radiología intervencionista: estado del arte.

European Radiology Experimental, 8(1), 62. <https://doi.org/10.1186/s41747-024-00452-2>

Gorelik, N., Chong, J. & Dana, J. (2020). Reconocimiento de patrones en imágenes

musculoesqueléticas mediante inteligencia artificial. *European Journal of Radiology*

Open. [https://www.thieme-connect.de/products/ejournals/abstract/10.1055/s-0039-](https://www.thieme-connect.de/products/ejournals/abstract/10.1055/s-0039-3400266)

[3400266](https://www.thieme-connect.de/products/ejournals/abstract/10.1055/s-0039-3400266)

Hashimoto, F., Gong, E., Watanabe, Y & Tanaka, H. (2019). Eliminación de ruido en imágenes

PET sin usar datos previos. *IEEE Access*, 7, 172592–172602.

<https://doi.org/10.1109/ACCESS.2019.2929230>

Hernández-Sampieri, R., Mendoza, C. & Baptista, P. (2022). *Metodología de la investigación*

(7.^a ed.). McGraw-Hill Education.

<http://187.191.86.244/rceis/registro/Metodolog%C3%ADa%20de%20la%20Investigaci%C3%B3n%20SAMPIERI.pdf>

Hospital Clínico Universidad de Chile. (2022). *Resúmenes. IV Jornadas de Investigación 2022: Salud e ingeniería: soluciones innovadoras en HCUCH* [Libro de resúmenes].

<https://www.redclinica.cl/Portals/0/Users/014/14/14/2485.pdf>

Kapoor, N., Lacson, R. & Khorasani, R. (2020). Aplicaciones del flujo de trabajo de la inteligencia artificial en radiología y descripción general de herramientas disponibles. *Journal of the American College of Radiology*, 17(11), 1460–1470.

<https://doi.org/10.1016/j.jacr.2020.08.016>

Lanas, M. (2022). *Detección automatizada de estructuras anatómicas retinales en retinografías digitales* [Tesis de Magíster, Universidad de Chile]. Repositorio Universidad de Chile.

https://cimt.uchile.cl/wp-content/uploads/2022/07/Tesis_Mitcheel_Lanas.pdf

Lanzafame, L., Bucolo, G., Muscogiuri, G., Sironi, S., Gaeta, M., Ascenti, G., Booz, C., Vogl, T., Blandino, A., Mazziotti, S. & D'Ángelo, T. (2023). Inteligencia artificial en imágenes cardiovasculares por TC y RM. *Life*, 13(2), 507. <https://doi.org/10.3390/life13020507>

Latif, J., Chuang, B., Imran, A., & Shanshan, T. (2019). Imágenes médicas mediante algoritmos de aprendizaje automático y aprendizaje profundo: una revisión. *IEEE International Conference on Metrology and Computing (ICOMET)*.

<http://dx.doi.org/10.1109/ICOMET.2019.8673502>

Lee, S. & Summers, R. (2021). Aplicaciones clínicas de inteligencia artificial en radiología: tórax y abdomen. *Radiologic Clinics of North America*, 59(5), 877–894.

<https://doi.org/10.1016/j.rcl.2021.07.001>

Liu, J., Malekzadeh, M., Niloufar, M., Tzu-An, S., Chi, L. & Joyinta, D. (2021). Mejora de imagen basada en IA en imágenes PET: reducción de ruido y mejora de la resolución. *Clinical PET/CT*, 16(4), 345–356. <https://doi.org/10.1016/j.cpet.2021.06.005>

- McBee, M., Awan, O., Colucci, A., Ghobadi, C., Kadom, N., Kansagra, A., Tridandapani, S. & Gabriel, M. (2018). Aprendizaje profundo en radiología. *Academic Radiology*, 25(11), 1472–1480. <https://doi.org/10.1016/j.acra.2018.02.018>
- Najjar, R. (2023). Redefiniendo la radiología: integración de la IA en imagenología médica. *Diagnostics*, 13(17), 2760. <https://doi.org/10.3390/diagnostics13172760>
- Panayides, A., Amini, A., Filipovic, N., Sharma, A., Tsaftaris, S., Golemati, S., Pattichis, C. (2020). AI in Medical Imaging Informatics: Current Challenges and Future Directions. *IEEE Journal of Biomedical and Health Informatics*, 24(7), 1837–1850. <https://doi.org/10.1109/JBHI.2020.2991043>
- Patil, S. & Panchal, P. (2023). Inteligencia Artificial en Radiología. *International Journal of Physiotherapy*, 10(2), 1-8. <https://journals.lww.com/ijpt/fulltext/2023/05020/>
- Prevedello, L., Halabi, S., Shih, G., Wu, C., Kohli, M., Katzen, J. & Erickson, B. (2017). Sistema automatizado de identificación y notificación en línea de hallazgos críticos mediante inteligencia artificial. *Radiology*, 285(3), 923-931. <https://doi.org/10.1148/radiol.2017162664>
- Rong, G., Mendez, A., Bou Assi, E., Zhao, B. & Sawan, M. (2019). Artificial intelligence in healthcare: Review, analysis and recommendations. *Engineering*, 5(6), 1011–1019. <https://doi.org/10.1016/j.eng.2019.08.015>
- Salehi, A., Mirniaharikandehi, S., Ghafoorian, M., Rostamzadeh, N. & Moradi, M. (2023). Un estudio de CNN y aprendizaje por transferencia en imágenes médicas: ventajas, desafíos y perspectivas futuras. *Sustainability*, 15(7), 5930. <https://doi.org/10.3390/su15075930>

- Sarmiento, J. (2020). Aplicaciones de las redes neuronales y el Deep learning a la ingeniería biomédica. *Revista UIS Ingenierías*, 19(4), 11–24. <https://doi.org/10.18273/revuin.v19n4-2020001>
- Scott, M. & De Cecco, L. (2020). Inteligencia artificial de la A la Z: De la red neuronal al marco legal. *European Journal of Radiology*, 129, 109083. <https://doi.org/10.1016/j.ejrad.2020.109083>
- Snyder, H. (2019). Literature reviews as a research methodology: An overview and guidelines. *Journal of Business Research*, 104, 333–339. <https://doi.org/10.1016/j.jbusres.2019.07.039>
- Torraco, R. (2016). Writing integrative literature reviews: Guidelines and examples. *Human Resource Development Review*, 15(4), 404–428. <https://doi.org/10.1177/1534484316671606>
- Tripathi, S., Ullah, I., Karri, S., Zakaria, N., Hussain, A. & Rauf, H. (2024). Del aprendizaje automático a los resultados del paciente: Una revisión de la IA en el cáncer de páncreas. *Diagnostics*, 14(2), 174. <https://doi.org/10.3390/diagnostics14020174>
- Wani, T. & Reshi, M. (2023). Revolucionando la radiología: IA en diagnóstico por imágenes. *International Journal for Multidisciplinary Research*, 5(6), 1–7. <https://doi.org/10.36948/ijfmr.2023.v05i06.10291>
- Whittemore, R. & Knafl, K. (2005). The integrative review: Updated methodology. *Journal of Advanced Nursing*, 52(5), 546–553. <https://doi.org/10.1111/j.1365-2648.2005.03621.x>
- Zhang, W. & Sejdić, E. (2019). Radiological images and machine learning: Trends, perspectives, and prospects. *Computers in Biology and Medicine*, 108, 354–370. <https://doi.org/10.1016/j.combiomed.2019.02.017>