

**Las redes neuronales y su impacto en la calidad de las imágenes de tomografía
computarizada**

Erika Arroyave Correa

Wilmar Alejandro Correa Vallejo

Deibis José Gómez Arenas

David Santiago Rivera Velásquez

Marisol Velásquez Goez

Asesor

Edna Rocío Jamaica Guío

Universidad Nacional Abierta y a Distancia - UNAD

Escuela de Ciencias de la Salud - ECISA

Programa: Tecnología en Radiología e Imágenes Diagnósticas

2025

Agradecimientos

Con profunda gratitud, queremos expresar nuestro reconocimiento a quienes han sido pilares fundamentales en este camino de aprendizaje. A nuestras familias, por su apoyo incondicional, comprensión y motivación en cada paso que hemos dado. A la Universidad Nacional Abierta y a Distancia (UNAD), por brindarnos la oportunidad de fortalecer nuestro conocimiento a través de una educación de calidad, accesible e innovadora. Y, por supuesto, a nuestra docente, quien con dedicación, esfuerzo y compromiso nos ha guiado, transmitiendo su sabiduría con paciencia y entrega.

Gracias a cada uno de ustedes por hacer posible esta experiencia enriquecedora, por impulsar nuestro crecimiento y por contribuir al desarrollo de nuestras habilidades. Todo lo aprendido no solo nos impulsa a nuevos retos, sino que nos motiva a seguir construyendo un mejor futuro con responsabilidad y pasión.

¡Nuestro más sincero agradecimiento!

Dedicatoria

Dedicamos este proyecto, en primer lugar, a Dios, por guiarnos en cada paso, brindarnos

fortaleza en los momentos de dificultad y permitirnos culminar con éxito esta etapa.

Al equipo en general, por el apoyo mutuo, el trabajo en equipo y la disposición para crecer juntos

durante este proceso. Gracias por compartir conocimientos, por las palabras de aliento en los momentos difíciles y por construir un ambiente de respeto, amistad y colaboración que hizo esta

experiencia mucho más enriquecedora.

A nuestra docente Edna Rocío por su dedicación, paciencia y por compartir con nosotros sus conocimientos con tanto compromiso. Ha sido una pieza clave para el desarrollo de este trabajo en todo momento, guiándonos con entrega y profesionalismo. Le agradecemos profundamente su

valioso acompañamiento durante este proceso.

Y a nuestras queridas mascotas, por su compañía fiel, que nos brindó consuelo, alegría y

momentos de calma en medio del esfuerzo.

Resumen

El presente trabajo presenta una revisión bibliográfica exhaustiva de la literatura científica sobre el uso de redes neuronales artificiales (RNA) en la mejora de la calidad de las imágenes en tomografía computarizada (TC). A partir del análisis crítico de literatura académica reciente, se evalúan diferentes bibliografías con el objetivo de establecer un marco de referencia en relación con los artefactos presentes en las imágenes de TC. La investigación sintetiza enfoques metodológicos claves e identifica beneficios, desafíos y perspectivas del uso de modelos de aprendizaje profundo aplicados a imágenes médicas, destacando técnicas para la mitigación de artefactos y el potencial de las RNA para reducir la dosis de radiación. Tras la revisión, se logran identificar ciertas ventajas en el diagnóstico, gracias a la aplicación de redes neuronales para la mitigación de estos artefactos y la mejora de la calidad de imagen. Es por esto que se llega a una conclusión de que las redes neuronales artificiales (RNA) representan una herramienta prometedora para optimizar el control de calidad y la precisión diagnóstica en TC, aunque su implementación requiere una cuidadosa consideración de los aspectos técnicos y clínicos asociados.

Palabras clave: Artefactos en TC, Redes Neuronales, Control de Calidad, Tomografía Computarizada.

Abstract

This work presents a comprehensive literature review on the use of artificial neural networks (ANNs) to improve image quality in computed tomography (CT). Based on a critical analysis of recent academic literature, various bibliographies are evaluated to establish a frame of reference in relation to artifacts present in CT images. The research synthesized key methodological approaches and identified benefits, challenges, and perspectives of using deep learning models applied to medical imaging, highlighting techniques for artifact mitigation and the potential of ANNs to reduce radiation dose. From the review, certain advantages in diagnosis are identified, thanks to the application of neural networks for the mitigation of these artifacts and the improvement of image quality. It is concluded that ANNs represent a promising tool to optimize quality control and diagnostic accuracy in CT, although their implementation requires careful consideration of the associated technical and clinical aspects.

Keywords: Artifacts in CT, Neural Networks, Quality Control, Computed Tomography

Tabla de contenido

Introducción	11
Planteamiento del Problema	12
Justificación	14
Objetivos	16
Objetivo General	16
Objetivos Específicos	16
Marco teórico	17
Generalidades Acerca de las modalidades de Tomografía Computarizada TC	17
Funcionamiento básico de la tomografía	17
Principios físicos de la tomografía	20
Formación de la imagen en tomografía computarizada	24
Artefactos más frecuentes en Tomografía computarizada	26
Tomografía computarizada	26
Artefactos en tomografía computarizada	27
Corrección de artefactos	31
Métodos manuales para la corrección de artefactos	31
Redes neuronales	32
Funcionamiento de las redes neuronales	33
Tipos de redes neuronales	34
Elementos básicos que componen una red neuronal	37
Ventajas y desventajas de las Redes Neuronales	39
Redes neuronales vs. computadoras digitales	41

	7
Desventajas.....	41
funcionamiento y entrenamiento de redes neuronales artificiales.....	42
Aprendizaje por refuerzo	43
Aprendizaje estocástico	43
Aprendizaje no supervisado.....	43
Consideraciones sobre el aprendizaje y los patrones en redes neuronales.....	43
Configuraciones clave del entrenamiento.....	44
Detención del aprendizaje.....	44
Codificación de datos.....	44
Atributos numéricos.....	44
Atributos simbólicos	44
Validación.....	45
Campos de aplicación de las redes neuronales	45
Biología.....	45
Empresa	45
Medio ambiente.....	45
Finanzas	45
Manufacturación.....	45
Medicina	46
Militares	46
Marco Metodológico	47
académicos, revistas científicas y documentos técnicos.....	47
Fuentes de Información.....	47
Modelo de Recopilación de Datos	48

	8
Criterios de selección.....	48
Criterios de exclusión	48
Organización de la información	48
Idioma y región	48
Procedimientos.....	49
Búsqueda inicial.....	49
Selección de documentos.....	49
Análisis crítico.....	49
Organización de hallazgos.....	49
Análisis de Datos.....	49
Resultados	51
Resultados cuantitativos extraídos de la literatura revisada	52
Interpretabilidad limitada.....	57
Dependencia de datos masivos.....	57
Limitada validación clínica	57
Altos requerimientos tecnológicos.....	57
Conclusiones	60
Recomendaciones	62
Referencias Bibliográficas	64

Lista de Tablas

<i>Tabla 1 Evolución Tecnológica de la Tomografía</i>	<i>18</i>
<i>Tabla 2 Características Principales de un Tomógrafo</i>	<i>20</i>
<i>Tabla 3 Resultados Cuantitativos Relevantes Extraídos de la Literatura Revisada.....</i>	<i>53</i>

Lista de Figuras

Figura 1 <i>Movimiento Helicoidal en Tomografía Computarizada</i>	21
Figura 2 <i>Funcionamiento de Tubo de Rayos X en Sistemas de Tomografía Computarizada</i>	21
Figura 3 <i>Escala Hounsfield en Tomografía Computarizada</i>	24
Figura 4 <i>Absceso Cerebral: Diagnostico, Manejo, Complicaciones y Pronósticos</i>	27
Figura 5 <i>Artefacto por Movimiento</i>	28
Figura 6 <i>Artefacto Metálico en Tomografía</i>	29
Figura 7 <i>TC de Tórax, Corte Axial, en Ventana Mediastino</i>	30
Figura 8 <i>Imagen de TC de cráneo Simple, Corte Axial</i>	31
Figura 9 <i>Representación de Neuronas Artificiales: (a) de una entrada y (b) de múltiples entradas</i>	34
Figura 10 <i>Redes Neuronales de Una Capa y Multicapa</i>	35
Figura 11 <i>Multilayer Perceptron (MLP), (b) Red Neuronal de Hopfield, (c) Self-Organizing Map (SOM)</i>	35
Figura 12 <i>(d) Red Neuronal Profunda (DNN), (e) Deep Auto-Encoder (DAE), (f) Red Neuronal Recurrente (RNN)</i>	36
Figura 13 <i>(g) Máquina Restringida de Boltzmann (RBM), (h) Red Neuronal de Creencias Profundas (DBN)</i>	36
Figura 14 <i>(i) Red Neuronal Convolutacional (CNN)</i>	37

Introducción

En el campo de la radiología, la velocidad y precisión en el diagnóstico son determinantes para el bienestar del paciente. En este contexto, la tecnología y la inteligencia artificial se han convertido en aliados indispensables para optimizar los procesos y mejorar la calidad de la atención médica. Las Redes Neuronales (RNNs), los cuales son modelos computacionales inspirados en el cerebro humano, han demostrado ser herramientas poderosas en el campo de la Inteligencia Artificial. Su capacidad para aprender patrones complejos a partir de grandes cantidades de datos las convierte en una solución prometedora para diversas aplicaciones.

Las redes neuronales recurrentes (RNNs) están revolucionando el campo de la radiología al optimizar el análisis e interpretación de imágenes médicas. Estas herramientas avanzadas no solo permiten la detección temprana de anomalías y una segmentación anatómica más precisa, sino que también están siendo aplicadas en tomografía computarizada (TC) para enfrentar retos clave como la reducción de artefactos, la minimización de la dosis de radiación y la mejora en la calidad de reconstrucción de las imágenes, lo que se traduce en diagnósticos más exactos y seguros.

Este trabajo de investigación se centra en el estudio del uso de redes neuronales recurrentes (RNNs) en el ámbito de la tomografía computarizada, con énfasis en su influencia sobre la calidad diagnóstica y la necesidad de que los profesionales de la salud comprendan adecuadamente el funcionamiento de estos algoritmos. Mediante una revisión detallada de la literatura científica más relevante, se analizarán tanto los beneficios como las limitaciones de estas tecnologías, con el objetivo de ofrecer una perspectiva completa, crítica y actualizada sobre un campo que evoluciona rápidamente y que tiene un impacto creciente en la práctica clínica

Planteamiento del Problema

En el área de la Radiología, la correlación entre el diagnóstico precoz y veraz de las imágenes diagnósticas y su interpretación acertada en el menor tiempo posible es crucial para el beneficio del paciente. Sin embargo, este proceso puede verse comprometido por el número creciente de estudios y pacientes que saturan las salas hospitalarias. En este contexto, las nuevas tecnologías y los avances en Inteligencia Artificial juegan un papel importante. Para los tecnólogos en Imágenes Diagnósticas, es vital garantizar la calidad y precisión de las imágenes diagnósticas, permitiendo así al médico tratante realizar un diagnóstico adecuado y proporcionar el tratamiento idóneo al paciente en el menor tiempo posible.

Uno de los problemas más significativos en la adquisición de imágenes diagnósticas son los artefactos, que pueden ser producidos por diferentes motivos, como el movimiento, aliasing y artefactos de anillo, entre otros. La evolución de las redes neuronales ofrece soluciones innovadoras y eficientes para mejorar la calidad de las imágenes y reducir estos artefactos, lo que se traduce en diagnósticos más precisos y tratamientos más efectivos para los pacientes al reducir el tiempo de procesamiento y mejorar la resolución de las imágenes.

Para contextualizar esta investigación, al comparar los resultados de un médico general que utiliza una Red Neuronal Artificial para diagnosticar casos con los de un médico especializado, se observa que un médico especializado tiene un 92% de efectividad, mientras que un médico general alcanza un 79%. Sin embargo, si este último utiliza una Red Neuronal Artificial, su efectividad aumenta a un 87.1% (Redes Neuronales Artificiales en la Medicina, 2021). Esto demuestra el impacto significativo del uso de redes neuronales en el ámbito de la salud.

En el campo de las imágenes diagnósticas, el uso de las redes neuronales aporta en diversos niveles. El principal, es la mejora de la calidad de las imágenes obtenidas por medio de la reducción de artefactos asociados a las mismas. Si se enfoca el uso de esta tecnología en un campo específico como la tomografía computarizada, se identifica el gran impacto en la calidad de las imágenes, contribuyendo a una interpretación más certera de diversas patologías. Sin embargo, la entrada de este tipo de transformaciones implica un conocimiento previo acerca del tema, para poder ahondar en las buenas prácticas en cuanto al uso de las redes neuronales para mejora de la imagen tomográficas

De todo el contexto anterior surge la pregunta que da origen al presente documento investigativo y es ¿cuáles son las redes neuronales más utilizadas en el ámbito de la tomografía computarizada y que impacto tienen sobre la calidad de las imágenes médicas en esta modalidad diagnóstica?

Justificación

La tomografía computarizada TC facilita la observación de la anatomía corporal a través de cortes transversales en distintos planos. Para la obtención de estas imágenes diagnósticas, se utilizan avanzados algoritmos de reconstrucción que utilizan los datos en brutos recolectados por la matriz detectora para moldear y abarcar las estructuras internas del cuerpo humano, permitiendo que estas se puedan visualizar a través de una escala de grises vinculada a la densidad del tejido que lo compone. Existen una amplia gama de artefactos en las imágenes que surgen de la relación entre los equipos y el paciente, por lo que se hace importante el abordaje de estos, ya que la no detección temprana puede provocar reportes incorrectos u ocultar una enfermedad importante. Entre los artefactos más importantes se encuentran: cuerpos extraños, artefacto de los blancos por alteración de los detectores o error de estabilidad, penumbra, factores ambientales, entre otros.

El avance de la tecnología, ha demostrado su impacto en la medicina, con el uso, cada vez mas frecuente de la inteligencia artificial para diferentes procedimientos de diagnóstico y tratamiento. Es así, como el uso de las redes neuronales ha aportado en gran medida a la mejora de la calidad en el contexto de las imágenes diagnósticas. Sin embargo, es claro que el desconocimiento del buen uso estas tecnologías puede traer como consecuencia fallas en la calidad de las imágenes médicas, acarreado la posibilidad de diagnósticos errados. Este trabajo de investigación cobra relevancia por la necesidad de identificar, a partir de la revisión exhaustiva de la literatura, las tecnologías asociadas a redes neuronales más utilizadas en la modalidad de tomografía computarizada. De la misma forma, resulta pertinente informar a los lectores acerca de sus ventajas, desventajas y del impacto actual para los procesos de

adquisición de la imagen y, sobre todo, su importancia frente a la calidad diagnóstica de los estudios realizados.

Es por ello, que este documento centra sus esfuerzos en evaluar las diferentes técnicas basadas en redes neuronales para la reducción de artefactos y pretende dar a conocer los avances más específicos para la gestión de la calidad de las imágenes en tomografía computarizada.

Objetivos

Objetivo General

Identificar el impacto de las redes neuronales en el mejoramiento de la calidad de las imágenes de tomografía computarizada.

Objetivos Específicos

Identificar y desarrollar una comprensión crítica de las metodologías utilizadas en la optimización de imágenes médicas mediante inteligencia artificial a partir de la revisión de literatura académica especializada.

Evaluar las ventajas y limitaciones del uso de deep learning en la reducción de dosis de radiación sin comprometer la calidad de la imagen.

Identificar modelos recientes de aprendizaje profundo que han demostrado eficacia en la mejora de imágenes médicas.

Fomentar la adquisición de conocimiento a través de la revisión y valoración exhaustiva de información y literatura, tanto a nivel grupal como individual, con el fin de mejorar la comprensión y difusión del uso de redes neuronales en el procesamiento de imágenes médicas.

Marco Teórico

Generalidades Acerca de las modalidades de Tomografía Computarizada TC

La tomografía computarizada (TC) es una técnica de diagnóstico médico que utiliza rayos X para obtener imágenes detalladas del cuerpo humano, proporcionando cortes transversales del organismo en diferentes planos (axial, sagital, coronal). Esta tecnología permite observar estructuras internas con mayor precisión que las radiografías convencionales.

En 1971 cuando se introducía a la clínica era una técnica de rayos X que solo permitía adquirir imágenes en cortes axiales del cerebro para su uso en neuroradiología. Al pasar el tiempo se fue volviendo versátil de tal manera que se podían obtener imágenes de rayos X de cualquier área del cuerpo pudiéndose aplicar a cualquier rama de la medicina.

Primero fueron escáner de una sola fila de detectores lo que permitía adquirir imágenes axiales, luego fueron evolucionando los equipos y se crearon escáner de múltiples filas de detectores los cuales permitieron evaluar anatómicamente cualquier parte del cuerpo humano. (Geleijns, 2010 vol. 11)

Se pueden ver equipos para tratamientos de radioterapia, también escáner para nuevas técnicas tales como (PET y SPECT), con el fin de atender pacientes con patologías oncológicas a las cuales se les pueda dar un tratamiento específico y directo. (Geleijns, 2010 vol. 11)

Funcionamiento Básico de la Tomografía

En cuanto a la adquisición de la imagen en TC el principal objetivo es medir los rayos X atenuados al atravesar el paciente, esta información la reciben filas de detectores ubicados al lado contrario del tubo de rayos X en el gantry. Cada tejido del cuerpo tiene designado una numeración en la escala de Unidades Hounsfield, esta numeración es utilizada en tomografía para realizar la reconstrucción de la imagen después de la exposición de un tejido a los rayos X.

Dependiendo del área el cuerpo a estudiar se realizan los protocolos establecidos para la adquisición de las imágenes, de eso depende el uso de radiación, factor importante a tener en cuenta y no causar daños irreversibles en los tejidos. Cabe mencionar que, en algunos casos, es necesario el uso de medios para visualización de estructuras en el cuerpo las cuales no son visibles a simple vista con solo radiación, en esos casos se utilizan materiales yodados como medio de contraste y así realzar dichas estructuras.

Tabla 1

Evolución Tecnológica de la Tomografía

Tecnología TC	Configuración del detector	Cobertura del campo de visión axial	Adquisición angular de las proyecciones	Cobertura longitudinal
Primeros escáneres clínicos 1974	Un único elemento detector	Haz estrecho, cobertura del FOV con traslaciones del tubo y del elemento detector	Rotación de un tubo de rayos X y del detector (Pequeños incrementos angulares)	Traslación de la camilla en pasos cortos
Escáneres de TC axial(step-and-shoot)	Fila única de detectores con cientos de canales	Haz en abanico con cobertura completa del FOV	Una rotación completa (360°) de un tubo de rayos X y del detector	

Escáneres de TC helicoidal			Rotación múltiple continua de un tubo de rayos X y del detector	Traslación continua de la camilla
Escáneres de TC helicoidal con múltiples filas de detectores	Multidetector con 4,16 y 64 canales activos			
Escáneres de TC helicoidal con múltiples filas de detectores y doble fuente	Dos conjuntos multidetectores con 32 o 64 canales activos	Dos haces en abanico, uno de ellos al menos con cobertura completa del FOV	Rotación múltiple continua de dos tubos de rayos X y de dos conjuntos de detectores	La cobertura de 160mm del campo longitudinal es proporcionada por el haz cónico. Para cobertura longitudinal >160mm: adquisiciones
Escáneres de TC volumétrico	Multidetector con hasta 320 canales activos	Haz cónico con cobertura del volumen de interés (FOV completo y 160mm longitudinal)	Una única rotación continúa de un tubo de rayos X y del detector.	atep-and shoot + enlace de volúmenes reconstruidos

Nota. Se muestran los cambios esenciales en la configuración del sistema detector, la cobertura del campo de visión axial, la configuración de adquisición axial, y la cobertura del campo longitudinal. Fuente: <https://revistadefisicamedica.es/index.php/rfm/issue/view/10> Vol.

11 Núm. 3 (2010)

Tabla 2*Características Principales de un Tomógrafo*

Característica de TC	
Tecnología	Rayos X y procesamiento computarizado.
Radiación	Usa radiación ionizante (rayos X).
Tiempo del examen	Rápido (generalmente minutos).
Resolución en tejidos blandos	Menos detallada comparada con RMN.
Indicaciones principales	Fracturas óseas, lesiones pulmonares, tumores, emergencias.
Costo	Más accesible y económico.
Limitaciones	Exposición a radiación, no tan útil para tejidos blandos.

Nota. Esta tabla presenta las características básicas de los tomógrafos. *Fuente:*

<https://www.nibib.nih.gov/espanol/temas-cientificos/tomograf%C3%ADa-computarizada-tc>

Principios Físicos de la Tomografía


Al hablar de los principios físicos de la TC debemos partir de dos puntos importantes, como lo son: La interacción de los rayos x y la atenuación de estos. Son calculados mediante una serie de ecuaciones que van a variar según el principio físico que se vaya a estudiar.

Según A Calzado y J Geleijns (2020) con el coeficiente de atenuación lineal n . La ley de Beer-Lambert establece la relación entre la intensidad del haz inicial de rayos X, I_0 , el coeficiente de atenuación lineal n , el espesor del material x , y la intensidad del haz atenuado de rayos X, $I(x)$. Combinado esto con la matriz de la imagen y la cantidad de voxeles, estos dos últimos van a depender del tipo del estudio y la cantidad de cortes que se realicen.

Los diferentes tomógrafos de la actualidad suelen ser multicortes helicoidal donde hay un giro continuo del tubo de los rayos x

Figura 1

Movimiento Helicoidal en Tomografía Computarizada




Nota. Tomografía computarizada dirigida a técnicos superiores en imagen para el diagnóstico.

Acosta, J. Soria, A. 2015.

Figura 2

Funcionamiento de Tubo de Rayos X en Sistemas de Tomografía Computarizada



Nota. Manual Practico de tomografía. González, J. 2011.

Una vez los rayos x atraviesan el tejido a estudiar y chocan con los detectores del TC de la siguiente manera desde el punto de vista imagenológico. La siguiente ecuación, es una forma

de la Ley de Beer-Lambert, y se usa mucho en tomografía computarizada (CT) y en física médica en general: $I_i(d) = I_0 \cdot e^{-(\sum_{j=1}^{512} \mu_j \cdot \Delta x)}$.

Donde:

$I_i(d)$: Intensidad final detectada del haz de rayos X en la dirección *d.

I_0 : Intensidad inicial del haz antes de atravesar el objeto.

μ_j : Coeficiente de atenuación lineal en el punto *j, que depende del tipo de tejido.

Δx : Espesor del voxel o segmento de tejido atravesado.

$\sum_{j=1}^{512}$ *: Suma de la atenuación a lo largo de los 512 píxeles de recorrido del haz.

Según, A Calzado y J Geleijns (2020) El principio básico de funcionamiento de la TC arranca con la medida de las intensidades del haz de rayos X inicial y final, I_0 e $I(d)$, respectivamente. A continuación, se aplican las diferentes técnicas de reconstrucción de la imagen para obtener una matriz de los coeficientes de atenuación lineal de la transmisión medida $I(d)/I_0$.

El gantry que contiene el tubo de rayos x en conjunto con otros complementos del tomógrafo van producir una cantidad de rayos x suficiente que pueden ser hasta 120 Kv para atravesar estructuras que van a formar múltiples imágenes que serán enviadas a un software para su construcción y procesamientos ya que por si solas no se pueden interpretar. Pero que para su reconstrucción se debe medir la intensidad de los rayos x en el detector mediante la siguiente ecuación, la cual describe cómo se atenúa o disminuye la intensidad de un haz de rayos X al atravesar un material homogéneo, es decir, un medio donde el coeficiente de atenuación μ es constante. Esta representa una ecuación más simple de la Ley de Beer-Lambert: $I(x) = I_0 e^{-\mu x}$

Donde:

$I(x)$: Intensidad del haz de rayos X tras atravesar el material.

I_0 : Intensidad inicial del haz.

μ : Coeficiente de atenuación lineal.

x : Espesor del material atravesado.

Según, Giraldo, J. Arboleda, C. McCollough. (2008) Esta fórmula tiene dos implicaciones importantes La primera, que el detector registra la integral de línea y esta depende de las atenuaciones en cada región del objeto en la trayectoria del rayo (regiones que fueron divididas en vóxels). La segunda, que, aunque se usa información volumétrica (vóxels), el detector registra la proyección $p(x)$, que es una señal unidimensional para cada ángulo θ .

Gracias al ingeniero Godfrey Newbold Hounsfield Una vez esta imagen están procesadas se le debe ingresar una serie de parámetros al sistema mediante una ecuación que le de valores a una serie de tejidos u órganos mediante un coeficiente de atenuación lineal de la siguiente manera: $UH_{mat} = (\mu_{mat} - \mu_{agua} / \mu_{agua}) \times 1000$. Esta fórmula sirve para calcular el valor en Unidades Hounsfield de un material o tejido específico, comparándolo con el agua. Es fundamental para interpretar las imágenes de tomografía porque los valores HU permiten diferenciar entre distintos tipos de tejidos.

Donde:

UH_{mat} : Unidad Hounsfield del material.

μ_{mat} : Coeficiente de atenuación del material.

μ_{agua} : Coeficiente de atenuación del agua.


1000: Factor multiplicador para expresar el resultado en unidades Hounsfield (HU).

Según, A Calzado y J Geleijns (2020) atenuación lineal (U mat) se transforma en una matriz de números de TC medidos en unidades Hounsfield del material o tejido correspondiente (UH mat). La atenuación de los materiales o tejidos en la escala Hounsfield se expresa en relación con el coeficiente de atenuación lineal del agua a temperatura ambiente (U agua).

De aquí surgen los valores que se le dan a diferentes tejidos y órganos del cuerpo humano una vez son atravesados por los rayos x, tomados por los detectores y procesados por el coeficiente de atenuación lineal.

Figura 3

Escala Hounsfield en Tomografía Computarizada



Nota Tomografía computarizada dirigida a técnicos superiores en imagen para el diagnóstico.

Acosta, J. Soria, A. 2015.

Formación de la Imagen en Tomografía Computarizada.

La creación de la imagen en Tomografía Computarizada (TC) se fundamenta en la obtención de varias proyecciones de rayos X desde diferentes ángulos alrededor del paciente, que posteriormente son procesadas por algoritmos matemáticos para reconstruir cortes transversales del cuerpo.

“La formación de una imagen de TC depende de la absorción diferencial de rayos X por diferentes tejidos y de la reconstrucción matemática de los datos adquiridos a partir de múltiples proyecciones” (Seram, 2016).

El procedimiento se inicia al girar el tubo de rayos X, acompañado de un conjunto de detectores, alrededor del paciente, que se mantiene acostado en una camilla que puede moverse

longitudinalmente dentro del gantry. En el proceso de rotación, el tubo emite ondas de rayos X que penetran el organismo, y los distintos tejidos del cuerpo reducen estos rayos en una proporción mayor o menor, en función de su densidad y composición.

Los detectores situados en el lado contrario al tubo de radiación captan la radiación que ha pasado por el cuerpo y producen señales eléctricas correspondientes a la cantidad de radiación absorbida. Esta información se transforma en datos digitales y se envía a un computador y este a su vez emplea algoritmos de reconstrucción para convertir los datos en una imagen en escala de grises.

Cada elemento de la imagen generada simboliza un reducido volumen tridimensional del organismo, llamado voxel y que recibe un valor de atenuación expresado en unidades Hounsfield (UH), estos parámetros posibilitan la distinción de manera precisa entre diferentes clases de tejidos, y que a su vez facilitan la detección de estructuras anatómicas y posibles lesiones en la zona estudiada. Finalmente, la imagen se muestra en un monitor, donde el tecnólogo en radiología e imágenes diagnósticas puede realizar modificaciones y ajustes de ventana para potenciar el contraste y destacar aspectos particulares dependiendo del tipo de estudio.

“La tomografía computarizada transforma la información de la atenuación de los rayos X en imágenes digitales, utilizando algoritmos de reconstrucción que permiten obtener cortes precisos del cuerpo humano, mejorando significativamente el diagnóstico médico.” Hounsfield, (1973).

Comprender el proceso de formación de la imagen en tomografía computada TC, es fundamental ya que permite no solo valorar la calidad diagnóstica de una imagen, sino también identificar cómo los parámetros técnicos influyen en en la correcta formación de la imagen. Además, saber cómo se reconstruyen las imágenes mediante algoritmos computacionales

fortalece nuestra capacidad para interpretar estudios con criterio, lo cual es fundamental para una práctica profesional segura y eficiente.

Artefactos más Frecuentes en Tomografía Computarizada

Tomografía Computarizada

Procedimiento de diagnóstico médico que utiliza rayos X y procesamiento computarizado para producir imágenes detalladas de secciones transversales del cuerpo humano, que se combinan para crear imágenes tridimensionales" (Hounsfield, 1973). Es decir, es un método de diagnóstico por imágenes que emplea rayos X para capturar imágenes minuciosas del interior del organismo. En contraste con los rayos x convencionales ofrecen una imagen en dos dimensiones, la Tomografía Computarizada TC genera imágenes transversales en diferentes cortes (axial, coronal y sagital) del cuerpo, lo que facilita la visualización de estructuras internas con gran precisión y así poder tener una visión más clara de estructuras anatómicas y diferentes patologías

Cortes transversales


A: Corte axial

B: Corte coronal

C: Corte sagital

Figura 4

Absceso Cerebral: Diagnostico, Manejo, Complicaciones y Pronósticos



Nota. Imágenes Axial, Coronal y Sagital de cráneo. Revista chilena de radiología.

Alvarado, M. T 2019.

Artefactos en Tomografía Computarizada

Los artefactos en tomografía computarizada (TC) son distorsiones o errores en las imágenes que no corresponden a la anatomía real del paciente, pudiendo simular y ocultar patologías. Según Ortiz et al. (2015) un artefacto se define como "una distorsión, adición o error en una imagen que no tiene correlato en el sujeto o región anatómica estudiada"

Existen diferentes artefactos en tomografía computarizada

Artefactos por Movimiento

Son distorsiones en las imágenes que ocurren cuando el paciente se mueve, ya sea voluntaria o involuntariamente, durante la adquisición de la imagen. Estos movimientos pueden deberse a la respiración, los latidos cardíacos, la deglución u otros factores, y resultan en imágenes borrosas o con distorsiones que pueden dificultar la interpretación diagnóstica, según Martín et al. (2018), el movimiento del paciente es el principal factor responsable de la

generación de artefactos en tomografía computarizada. Es fundamental que las estructuras se mantengan estáticas durante los estudios, a pesar de la rapidez con la que se realizan las adquisiciones.

Figura 5

Artefacto por Movimiento




Nota. Imagen axial (A) y reconstrucción MPR sagital (B) de TC torácico. Se ve un doble contorno de pared en la raíz aórtica (flechas) debido al movimiento cardíaco, dando una falsa imagen de disección. *Fuente.* Seram., Cuartero, J. Et al. 2018.

Artefactos Metálicos

Los artefactos metálicos son alteraciones en las imágenes causadas por la existencia de elementos metálicos en el organismo del paciente, tales como prótesis, implantes o fragmentos metálicos. Estos artefactos suelen presentarse como trazos luminosos u oscuros que se proyectan desde el objeto de metal, lo que puede complicar la representación exacta de las estructuras anatómicas adyacentes. Según Ortiz et al. (2015), los artefactos metálicos son causados por la presencia de materiales de alta densidad en el paciente, lo que provoca distorsiones en las imágenes obtenidas por TC.

Figura 6

Artefacto Metálico en Tomografía



Nota. ELSEVIER. Revista Argentina de radiología. Ortiz., 2015.

Artefacto por Campo de Visión Limitado

Suceden cuando un segmento del paciente está más allá del campo de visión FOV (campo de visión), del escáner. Esto causa alteraciones en las imágenes adquiridas, dado que las zonas fuera del FOV no se registran adecuadamente, lo que puede conducir a interpretaciones equivocadas o a la supresión de descubrimientos de relevancia clínica. Según Ortiz et al. (2015), los artefactos en TC pueden surgir debido a la interacción entre el paciente y el tomógrafo, y su reconocimiento es crucial para evitar diagnósticos incorrectos o la ocultación de patologías. Aunque no se menciona específicamente el artefacto por campo de visión limitado, se destaca la importancia de identificar y mitigar diversos tipos de artefactos para garantizar la calidad de las imágenes obtenidas.

Figura 7

TC de Tórax, Corte Axial, en Ventana Mediastino



Nota. Artefacto producido por la presencia de hueso de la zona de los brazos. Fuente.

ELSEVIER. Revista Argentina de radiología, Ortiz., 2015.

Artefactos por Interferencia Del Sistema

Son alteraciones en las imágenes causadas por dificultades técnicas o fallos en el equipo de escaneo. Estos artefactos pueden presentarse en forma de líneas, bandas o patrones extraños que no están relacionados con la anatomía del paciente y pueden complicar la interpretación del diagnóstico. Según Cruz Serrano (2022), los artefactos pueden deberse a múltiples causas, incluyendo fallos del sistema, y se observan como rayas, ruido, anillos o bandas en las imágenes. Es fundamental estar familiarizados con estos artefactos para detectarlos y evitar que simulen patologías falsas

Figura 8

Imagen de TC de cráneo Simple, Corte Axial



Nota. se evidencian Múltiples anillos concéntricos que aparentan una "rueda de carro" (flechas). Fuente. ELSEVIER. Revista Argentina de radiología. Ortiz., 2015.

Corrección de Artefactos

La corrección de artefactos puede definirse como procedimientos empleados para disminuir o erradicar alteraciones en las imágenes médicas provocadas por elementos técnicos, físicos o del propio paciente. Los artefactos pueden deteriorar la calidad de la imagen y complicar el análisis diagnóstico, existen métodos o técnicas de reducción de artefactos tanto manuales como también desde la parte operativa

Métodos Manuales para la Corrección de Artefactos

Hacen referencia a los métodos y modificaciones utilizados directamente por los expertos en imagenología para detectar, reducir o erradicar distorsiones indeseables en las imágenes médicas. Estos procedimientos exigen un entendimiento detallado de las posibles razones de los artefactos. Algunos de ellos son:

Modificación del Campo Visual (FOV)

Ampliar el FOV puede evitar artefactos de superposición o aliasing, en los que se reflejan de manera incorrecta partes de la anatomía fuera del campo de estudio.

Cambio en la Orientación de la Codificación De Fase

Modificar el rumbo de codificación puede contribuir a disminuir los artefactos por movimiento, dado que reparte las distorsiones a zonas menos críticas de la imagen.

Uso de bobinas de Superficie

El uso de bobinas específicas puede potenciar la relación entre señal y ruido en zonas de interés, disminuyendo la presencia de artefactos y elevando la calidad de la imagen.

Según García Gallardo et al. (2024), "El Técnico Superior en Imagen para el Diagnóstico (TSID) es el primer profesional que puede identificar estos artefactos y corregirlos." Lo que sugiere que el tecnólogo en radiología e imágenes diagnósticas desempeña un papel fundamental en la calidad de las imágenes médicas ya que es el primer profesional en detectar y corregir artefactos, lo que resalta su responsabilidad en garantizar que las imágenes obtenidas y que estas sean diagnósticamente útiles.

Redes Neuronales

Las redes neuronales son modelos de computación basados en el funcionamiento cerebral humano, creados para identificar patrones y adquirir conocimientos de grandes cantidades de información. En el campo del tratamiento de imágenes médicas, estas redes han probado ser útiles para incrementar la exactitud y eficacia en labores como la identificación de irregularidades y la división de estructuras anatómicas.

Marvin Minsky y Seymour Papert (1969) en su obra *Perceptrons*, describen las redes neuronales como modelos de procesamiento de información basados en la estructura y función del cerebro humano. propone una perspectiva preliminar de estos modelos como estructuras informáticas inspiradas en el cerebro humano. Su perspectiva subraya la relevancia de la interrelación de unidades sencillas (neuronas artificiales) para manejar datos de forma distribuida y paralela, un principio fundamental en la inteligencia artificial de la actualidad.

Funcionamiento de las Redes Neuronales

Las redes neuronales se organizan en capas

Capa de Entrada

Recibe los datos iniciales y los envía a las próximas capas.

Capas ocultas

Examinan la información obtenida, llevando a cabo cálculos y obteniendo atributos relevantes.

Capa de Salida

Ofrece el resultado definitivo del procesamiento, como una categorización o pronóstico.

En su documento "Redes Neuronales Artificiales y sus Aplicaciones" la universidad del país Vasco (2008), describen que una red neuronal artificial típica consta de una capa de entrada, donde se presentan los datos a la red; una o más capas ocultas, que procesan la información; y una capa de salida, que produce la respuesta de la red. Aunque la descripción ofrecida por la Universidad del País Vasco es exacta, es crucial subrayar que la cantidad y profundidad de las capas ocultas tienen un impacto directo en el desempeño del modelo. Las redes neuronales de escasas capas podrían no interpretar patrones complejos, en cambio, redes profundas pueden conseguir representaciones más abstractas.

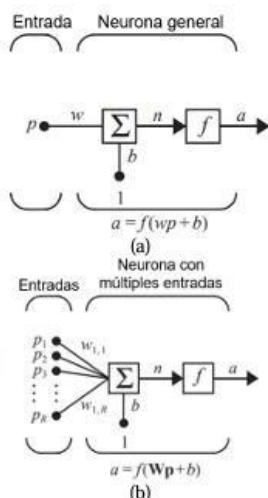
Tipos de Redes Neuronales

Las redes neuronales son creadas por complejos algoritmos computacionales que tienen como fin simular la inteligencia del cerebro humano, esto con el fin de enseñarle a un sistema de información funciones como: reconocimientos, clasificaciones, predicciones y diagnósticos.

Debemos partir del punto de que cada una de las neuronas que conforman la red van conectadas entre sí, es decir están compuestas por una o múltiples entradas donde la función es la transferencia de archivos. A continuación, podemos observar la representación algorítmica de las redes neuronales y la arquitectura de estas

Figura 9

Representación de Neuronas Artificiales: (a) de una entrada y (b) de múltiples entradas




Nota. Formula de entradas neuronales. Tomado de Revista UIS Ingenierías, Vol. 19, n.º 4, pp. 1-18, Sarmiento, J. 2020. Aplicaciones de las redes neuronales y el deep learning a la ingenieríabiomédica.

https://revistas.uis.edu.co/visores/Revista_UIS_Ingenierias_Vol_19_Num_4/553768213002/

Figura 10

Redes Neuronales de Una Capa y Multicapa



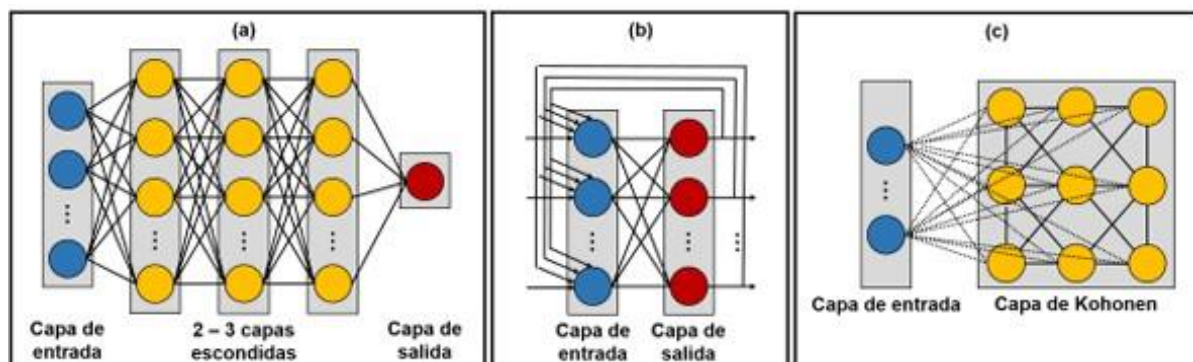
Nota. Formula de entradas neuronales multiples capas. Tomado de Revista UIS Ingenierías, Vol. 19, n.º 4, pp. 1-18, Sarmiento, J. 2020. Aplicaciones de las redes neuronales y el deep learning a la ingeniería biomédica.

[https://revistas.uis.edu.co/visores/Revista UIS Ingenierías Vol 19 Num 4/553768213002/](https://revistas.uis.edu.co/visores/Revista%20UIS%20Ingenierias%20Vol%2019%20Num%204/553768213002/)

A continuación, podemos ver la arquitectura de algunos tipos de redes neuronales mas usadas

Figura 11

Multilayer Perceptron (MLP), (b) Red Neuronal de Hopfield, (c) Self-Organizing Map (SOM)

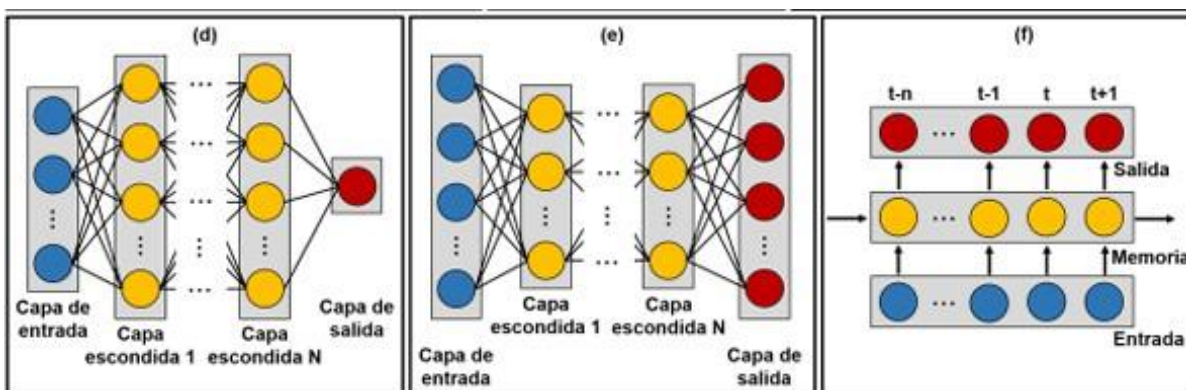


Nota. Arquitectura de las RN. Tomado de Revista UIS Ingenierías, Vol. 19, n.º 4, pp. 1- 18, Sarmiento, J. 2020. Aplicaciones de las redes neuronales y el deep learning a la ingeniería biomédica.

<https://revistas.uis.edu.co/visores/Revista UIS Ingenierias Vol 19 Num 4/553768213002/>

Figura 12

(d) Red Neuronal Profunda (DNN), (e) Deep Auto-Encoder (DAE), (f) Red Neuronal Recurrente (RNN)




Nota. Arquitectura de las RN. Tomado de Revista UIS Ingenierías, Vol. 19, n.º 4, pp. 1- 18, Sarmiento, J. 2020. Aplicaciones de las redes neuronales y el deep learning a la ingeniería biomédica.

<https://revistas.uis.edu.co/visores/Revista UIS Ingenierias Vol 19 Num 4/553768213002/>

Figura 13

(g) Máquina Restringida de Boltzmann (RBM), (h) Red Neuronal de Creencias Profundas (DBN)

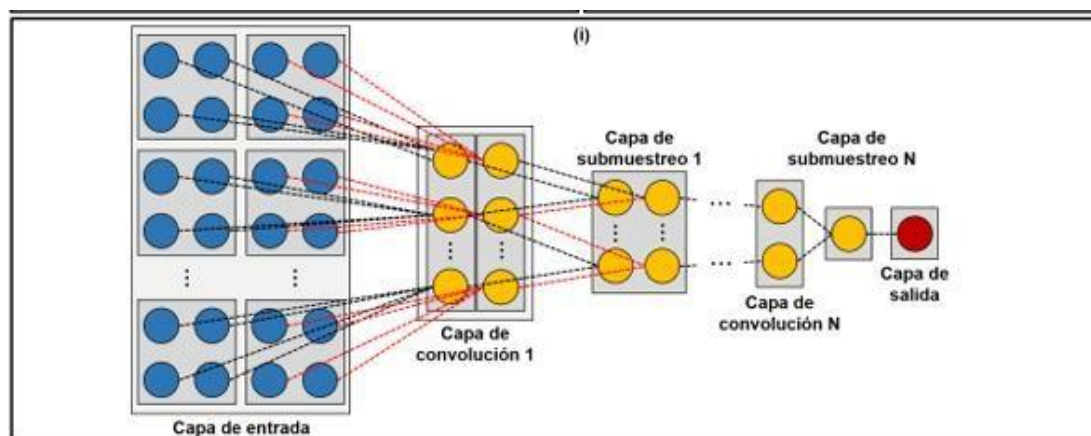


Nota. Arquitectura de las RN. Tomado de Revista UIS Ingenierías, Vol. 19, n.º 4, pp. 1- 18, Sarmiento, J. 2020. Aplicaciones de las redes neuronales y el deep learning a la ingeniería biomédica.

https://revistas.uis.edu.co/visores/Revista_UIS_Ingenierias_Vol_19_Num_4/553768213002/

Figura 14

(i) *Red Neuronal Convolutiva (CNN)*



Nota. Arquitectura de las RN. Tomado de Revista UIS Ingenierías, Vol. 19, n.º 4, pp. 1- 18, Sarmiento, J. 2020. Aplicaciones de las redes neuronales y el deep learning a la ingeniería biomédica.

https://revistas.uis.edu.co/visores/Revista_UIS_Ingenierias_Vol_19_Num_4/553768213002/

Elementos básicos que Componen una Red Neuronal

Neuronas (nodos o unidades)

Son las unidades fundamentales de procesamiento que reciben una entrada, la procesan mediante una función matemática, y generan una salida. Inspiradas en las neuronas biológicas.

Pesos (weights)

Son valores numéricos que modulan la importancia de cada entrada hacia una neurona y se ajustan durante el entrenamiento para que la red aprenda a realizar una tarea específica.

Bias (sesgo)

Es un valor adicional que se suma a la combinación de entradas ponderadas que permite que el modelo se desplace y ajuste la salida, incluso cuando todas las entradas son cero.

Función de Activación

Define cómo se transforma la salida de cada neurona e introduce no linealidad, permitiendo que la red aprenda relaciones complejas. Ejemplos comunes: ReLU, Sigmoid, Tanh.

En una red totalmente conectada (feedforward), cada neurona de una capa está conectada con todas las neuronas de la siguiente capa.

En tomografía computarizada la red neuronal es una herramienta que se usa para analizar automáticamente las imágenes. En pocas palabras ayudan a ver y entender las imágenes médicas realizadas de una TC, brindando múltiples beneficios al momento de obtener diagnósticos precisos, como:

Detección de Patologías

Una red neuronal puede identificar tumores, hemorragias, fracturas, lesiones pulmonares, etc. en las imágenes de TC. Ejemplo: detecta un nódulo pulmonar o una hemorragia cerebral automáticamente.

Segmentación Automática

Dibuja o separa automáticamente estructuras anatómicas (como el hígado, los pulmones o un tumor). Esto es muy útil para planificación quirúrgica o radioterapia.

Mejora de imagen (reconstrucción o reducción de ruido)

Algunas redes neuronales pueden mejorar la calidad de la imagen o reducir el ruido en tomografías con baja dosis de radiación. Así, se obtienen imágenes más claras con menos exposición al paciente.

Ventajas y desventajas de las Redes Neuronales

En la búsqueda de avances tecnológicos y mayor conocimiento, la humanidad ha logrado maravillas que antes parecían imposibles. Un ejemplo destacado son las redes neuronales, un área fascinante que comenzó a gestarse en la década de 1940. Fue entonces cuando los científicos Warren McCulloch y Walter Pitts propusieron un modelo matemático que imitara el funcionamiento del cerebro humano a través de la interconexión de neuronas.

Años más tarde, en 1958, Frank Rosenblatt presentó el "perceptrón", considerado como el primer intento de una neurona artificial. Este modelo, aunque sencillo, marcó el inicio del desarrollo de las redes neuronales modernas. Con el paso del tiempo, estas tecnologías se volvieron más sofisticadas. En la década de 1980 surgieron las redes convolucionales (CNN), especialmente efectivas para el procesamiento de imágenes, encontrando aplicaciones cruciales en áreas como la radiología y las imágenes diagnósticas.

En esencia, las redes neuronales buscan emular ciertas capacidades del cerebro humano, y hasta ahora los resultados han sido notables. Sin embargo, como toda innovación humana, estas tecnologías presentan tanto ventajas como desventajas. A continuación, se destacan algunos puntos clave, basados en obras como *Inteligencia Artificial y Redes Neuronales: Fundamentos, Ejercicios y Aplicaciones con Python y Matlab* de Vorobioff, Cerrotta, Morel y Amadio.

Las redes neuronales artificiales comparten características similares al cerebro humano, como la capacidad de aprender de la experiencia, generalizar, abstraer información relevante y adaptarse a nuevos datos. Esto les brinda diversas ventajas aplicables en múltiples áreas tecnológicas:

Aprendizaje Adaptativo

Aprenderán a través del entrenamiento con ejemplos, sin necesidad de modelos o funciones predefinidas.

Son sistemas dinámicos y autoajustables, capaces de seguir aprendiendo aún después del entrenamiento inicial.

El diseñador solo debe definir la arquitectura y un buen algoritmo de aprendizaje; la red se encarga del resto.

Autoorganización

Durante el aprendizaje, la red organiza por sí sola la información recibida.

Permite generalización, es decir, responder adecuadamente ante datos nuevos o incompletos.

Ejemplo: una red backpropagation genera su propia representación interna de patrones.

Tolerancia a Fallos

A diferencia de los sistemas tradicionales, las redes neuronales siguen funcionando aun con errores o pérdida parcial de neuronas.

Tienen redundancia en el almacenamiento de información, distribuida entre sus conexiones, lo que evita caídas críticas del sistema.

Operación en Tiempo Real

Gracias a su capacidad de procesamiento en paralelo, las redes pueden realizar tareas rápidamente.

Son ideales para aplicaciones donde se requiere procesamiento ágil y constante.

Fácil inserción en Tecnología Existente

Pueden integrarse fácilmente en sistemas ya existentes mediante hardware especializado.

Se entrenan de forma rápida y pueden ser implementadas en tareas específicas con bajo costo.

Se pueden agregar de forma modular para mejorar los sistemas sin reemplazarlos por completo.

Redes neuronales vs. Computadoras Digitales

Las redes neuronales no funcionan con lógica digital tradicional (síncrona o asíncrona).

Las neuronas biológicas operan de manera analógica , con entradas múltiples y umbrales variables, lo cual impide comportamientos binarios o recursivos como en los sistemas digitales.

No utilizan algoritmos tradicionales ni computación recursiva.

El cerebro humano es considerado un ordenador analógico , no algorítmico.

Desventajas

Complejidad

Requieren grandes volúmenes de datos para entrenarse de manera adecuada.

Tiempo de Entrenamiento

Este proceso puede ser largo y demandar muchos recursos computacionales.

Interpretabilidad

Resulta complicado entender cómo llegan a sus decisiones, lo cual puede ser un desafío en contextos críticos.

Dependencia de Datos

Necesitan datos de alta calidad para funcionar correctamente.

Consumo de Recursos

Requieren hardware potente, como GPUs, lo que incrementa los costos.

Riesgo de Sobreajuste

Sin control adecuado, podrían ajustarse demasiado a los datos de entrenamiento y fallar en datos nuevos.

Son difíciles de Interpretar

Esto hace difícil entender el motivo por el que llega a una cierta predicción, conclusión o probabilidad.

Problemas de Convergencia

Algunas veces quedan atrapadas en mínimos locales durante el entrenamiento, limitando su desempeño.

Impacto Ambiental

El alto consumo energético asociado a los entrenamientos prolongados puede tener implicaciones ecológicas.

Las redes neuronales representan una herramienta poderosa para procesar datos complejos y abordar tareas desafiantes. Sin embargo, a medida que aumentan su eficiencia y capacidad, también crecen los costos asociados, tanto económicos como ambientales. En resumen, el desarrollo y aplicación de estas tecnologías requieren un equilibrio cuidadoso entre sus beneficios y desafíos, pero seguramente en un futuro muy próximo podremos ver nuevas aplicaciones muy interesantes para las Redes Neuronales.

Funcionamiento y Entrenamiento de Redes Neuronales Artificiales

Las redes neuronales artificiales aprenden ajustando los valores de conexión entre sus “neuronas” (nodos). Estos valores determinan cuánto influye una entrada sobre la salida. Hay varios tipos de aprendizaje:

Aprendizaje por Refuerzo

No se da una salida correcta exacta, solo se indica si el resultado fue bueno (+1) o malo (-1).

La red ajusta sus valores de conexión basándose en esta retroalimentación, como si el sistema tuviera un crítico que opina, pero no enseña directamente

Es más lento que el aprendizaje supervisado, pero útil cuando no se conoce la respuesta exacta.

Aprendizaje Estocástico

Se modifican aleatoriamente los valores de conexión y se mide si la red mejora o no.

Se basa en una analogía física: como si la red buscara su estado más “estable” (menor energía).

Si un cambio mejora la red, se queda; si no mejora, se acepta solo a veces, dependiendo de probabilidades

Aprendizaje no Supervisado

La red aprende sola, sin saber si está “bien” o “mal”.

Busca patrones, similitudes y clasificaciones en los datos de entrada.

Consideraciones sobre el Aprendizaje y los Patrones en Redes Neuronales

Las redes neuronales se entrenan a partir de grandes volúmenes de datos, y según el tipo de aprendizaje utilizado, el sistema logra acoplarse al problema mediante la identificación de asociaciones entre las entradas y salidas. Sin embargo, este proceso no garantiza que las asociaciones aprendidas representen verdades causales. Muchas veces, el modelo puede estar explotando correlaciones que son irrelevantes o incluso engañosas. Esto se debe a la presencia de variables ocultas o factores de confusión (confounding factors), que afectan el comportamiento

del modelo sin ser detectados directamente. Este problema, conocido como "lurking variables", puede deteriorar gravemente la capacidad del modelo para generalizar a nuevos datos. Este aspecto ha sido enfatizado en el curso Fundamentals of Machine Learning for Healthcare de la Universidad de Stanford (Coursera, Módulo 5).

Configuraciones clave del Entrenamiento

Elección del conjunto inicial de valores de conexión

Se asignan de forma aleatoria dentro de un rango (por ejemplo, $[-n, n]$).

Durante el entrenamiento, estos valores se van ajustando sin restricción.

Detención del Aprendizaje

Se detiene cuando el error es muy pequeño o se llega a un número de ciclos definidos.

Después de detenerse, los valores de conexión ya no cambian más: el aprendizaje queda "grabado".

Codificación de Datos

Los datos deben transformarse en números para que la red los pueda procesar:

Atributos numéricos

Se transforman linealmente al rango $[0, 1]$, con un pequeño margen (buffer) para evitar errores si el valor real se sale del rango conocido.

Atributos Simbólicos

Sin orden

Se asigna una neurona binaria por cada valor.

Con Orden

Se representan con un solo número dentro de un rango (ej.: viejo = 0.33, medio = 0.66, joven = 1).

Validación

Una vez entrenada la red, se prueba con nuevos ejemplos que no ha visto antes. Se comparan las salidas obtenidas con las respuestas correctas para medir qué tan bien generaliza.

Campos de Aplicación de las Redes Neuronales

Las redes neuronales tienen una enorme variedad de campos de aplicación, gracias a su capacidad para aprender patrones complejos a partir de datos.

Existen numerosos tipos distintos de redes neuronales; cada uno con una aplicación específica más adecuada. Algunas aplicaciones de carácter comercial incluyen:

Biología

Usado generalmente para adquirir más información sobre el cerebro y otros sistemas.

Empresa

Usado generalmente para el análisis de la posibilidad de formaciones geológicas y de petróleo, identificación de aspirantes para puestos concretos, optimización de tiempos y fechas en las líneas aéreas, optimización del tránsito mediante el control adecuado de la programación de los semáforos, identificación de caracteres manuscritos. Entre otros.

Medio Ambiente

Usado generalmente para examinar tendencias y modelos, pronóstico del tiempo.

Finanzas

Usado generalmente para pronóstico del cambio en los precios, reconocimiento de estafas o falsificaciones, lectura de firmas.

Manufacturación

Usado generalmente para implementación de sistemas de control y robots automatizados con sensores de presión, temperatura y gas, evaluación de la calidad. Entre otros.

Medicina

Usados generalmente para implementación de analizadores auditivos para asistir en la identificación de sordos profundos, diagnóstico y terapia basados en síntomas y/o en información analítica, seguimiento en intervenciones quirúrgicas, previsión de reacciones adversas en los fármacos y comprensión de las razones de los ataques al corazón. Entre otros.

Militares

Usados generalmente para enumeración de las señales en radar, innovación en la fabricación de armas inteligentes, optimización en la utilización de recursos limitados. Entre otros.

"Las redes neuronales artificiales han demostrado un notable potencial para transformar múltiples disciplinas, desde la medicina y la ingeniería hasta las finanzas y el arte, gracias a su capacidad para aprender patrones complejos y tomar decisiones inteligentes a partir de grandes volúmenes de datos." Goodfellow, Bengio y Courville, (2016)

La cita de Goodfellow, Bengio y Courville (2016) muestra cómo las redes neuronales han logrado cambiar muchas áreas, desde la medicina hasta el arte. El uso de redes neuronales en medicina no solo mejora la eficiencia del trabajo médico, sino que también puede salvar vidas al detectar enfermedades de manera temprana. Es una herramienta que complementa el conocimiento del profesional de la salud y abre nuevas oportunidades para ofrecer una atención más personalizada y efectiva.

Marco Metodológico

Tipo de Estudio

El presente trabajo sigue un enfoque cualitativo de tipo documental, basado en el análisis crítico y explicativo de literatura especializada sobre redes neuronales y su aplicación en radiología digital. Se trata de una revisión sistemática que busca identificar, analizar y sintetizar los principales aportes teóricos y prácticos en el uso de inteligencia artificial para la mejora de la calidad de las imágenes médicas, con énfasis en Tomografía Computarizada (TC).

El enfoque cualitativo permite explorar y comprender fenómenos complejos a partir de la interpretación de datos no numéricos. En este caso, el método de investigación documental se centra en el estudio de información previamente publicada, con el fin de obtener una comprensión profunda sobre el impacto del uso de redes neuronales en la mejora de imágenes médicas. Este tipo de estudio no implica la recolección de datos empíricos directos, sino que se apoya en la revisión crítica de fuentes secundarias como libros, artículos académicos, revistas científicas y documentos técnicos.

Fuentes de Información

La recolección de los datos se basó en literatura blanca, es decir, fuentes confiables, debidamente verificadas y obtenidas de bases de datos científicas y de educación. Las bases de datos consultadas fueron Scielo, Dialnet, Elsevier y los repositorios de diferentes universidades entre las que se destacan UNAD, Universidad del Rosario, Universidad Nacional y reconocidas universidades latinoamericanas. Así también, se tuvieron en cuenta artículos de revistas médicas y de ingeniería.

Modelo de Recopilación de Datos

Criterios de Selección

Se priorizaron fuentes académicas con alto rigor metodológico, respaldo institucional y relevancia directa con el tema de estudio. Los documentos seleccionados debían estar escritos en español y tratar específicamente el mejoramiento de imágenes médicas mediante redes neuronales, con énfasis en Tomografía Computarizada. Dentro de los criterios de selección se tuvieron en cuenta artículos con rangos de tiempo entre el año 2020 y 2024. Se seleccionaron dos artículos con fechas anteriores, ya que contienen información relevante en cuanto a las generalidades.

Criterios de Exclusión

Se excluyeron fuentes sin validación académica, artículos que no abordaran aplicaciones médicas específicas o que no presentaran suficiente detalle técnico en sus metodologías. También se excluyeron aquellos textos que, aunque trataran sobre inteligencia artificial, redes neuronales o deep learning, no estuvieran directamente relacionados con el área de la salud ni con el impacto en el mejoramiento de las imágenes médicas.

Organización de la Información

Los textos se categorizaron por áreas temáticas como fundamentos teóricos de redes neuronales, aplicaciones clínicas en radiología digital, tomografía computarizada (TC) y metodologías de mejoramiento de imágenes mediante deep learning.

Idioma y Región

Todos los documentos analizados están escritos en español. Las publicaciones provienen de diversas regiones hispanohablantes, incluyendo España, Colombia, Argentina y otros contextos latinoamericanos.

Procedimientos

Búsqueda Inicial

Se realizó una exploración exhaustiva de literatura académica utilizando bases de datos indexadas y palabras clave como "redes neuronales", "inteligencia artificial aplicada a la salud" y "artefactos en imágenes médicas".

Selección de Documentos

Se filtraron los estudios con base en calidad académica, reconocimiento del autor y actualidad de la información.

Análisis Crítico

Se realizó una lectura detallada de cada texto para identificar conceptos clave, metodologías replicables y enfoques innovadores en la aplicación de deep learning e Inteligencia Artificial en imágenes de rayos X y Tomografía Computarizada.

Organización de Hallazgos

Este diplomado se desarrolla tanto de manera grupal como individual. Cada participante aporta elementos clave desde su revisión bibliográfica y análisis crítico, los cuales son posteriormente compilados y organizados en una estructura coherente que permita contrastar las distintas metodologías y su aplicabilidad en el contexto de la radiología digital.

Análisis de Datos

El análisis de datos en este estudio se basa exclusivamente en la revisión de la literatura existente. Según la literatura y referencias consultadas, la evaluación de la calidad de las imágenes mejoradas mediante redes neuronales se realiza a través de comparaciones visuales entre las imágenes originales y las optimizadas, considerando diferentes niveles de dosis de radiación o el mejoramiento de los artefactos en imágenes tomográficas. Se destaca un ejemplo

en el cuál una mayor dosis de radiación mejora la calidad de la imagen, pero incrementa los riesgos para el paciente. Por ello, las investigaciones analizadas buscan mejorar la calidad sin aumentar innecesariamente la exposición a la radiación, aprovechando la capacidad de las redes neuronales para optimizar la definición o la relación Señal/Ruido sin comprometer la seguridad del paciente.

Además, los estudios revisados subrayan la importancia de disponer de grandes volúmenes de datos para entrenar eficazmente los modelos de redes neuronales. La eficacia del aprendizaje profundo depende en gran medida de la diversidad y cantidad de imágenes utilizadas en el entrenamiento. Finalmente, se identificaron nuevos modelos de aprendizaje profundo que permiten mejorar no solo las imágenes de radiología convencional, sino también las de tomografía, ampliando el alcance y aplicabilidad de estas tecnologías en esta modalidad de diagnóstico por imágenes.

Las redes neuronales artificiales presentan ventajas significativas en el campo de la medicina. Son capaces de operar con datos incompletos o con ruido y se autoajustan a medida que se entrenan con más información, lo que les permite mejorar su capacidad de reconocimiento de patrones. En el ámbito de la radiología, estas propiedades hacen que sean herramientas valiosas para el diagnóstico y apoyo en la toma de decisiones clínicas. Sin embargo, también presentan desafíos como la necesidad de grandes volúmenes de datos para su entrenamiento, la dificultad en la interpretación de sus decisiones debido al fenómeno de la "caja negra", y su impacto ambiental derivado del alto consumo energético en el procesamiento de información.

Resultados

A partir del análisis de las fuentes revisadas, se identificaron múltiples enfoques en el uso de redes neuronales artificiales para el mejoramiento de imágenes en tomografía computarizada.

Entre los principales hallazgos se destacan:

El uso de RNA permite aumentar la resolución de las imágenes y reducir artefactos, especialmente los causados por movimiento, ruido y presencia de materiales metálicos (Match, 2001).

Las redes neuronales pueden sustituir técnicas de posprocesamiento convencionales, optimizando el tiempo de análisis clínico y la calidad de los estudios.

Modelos basados en aprendizaje profundo (deep learning) como las CNN (Redes Convolucionales) permiten mejorar imágenes sin necesidad de aumentar la dosis de radiación, lo que representa un avance en seguridad del paciente (Moreno Berdón, 2021).

Las RNA han sido entrenadas para reconocer patrones complejos en imágenes, lo que ha demostrado ser útil para corregir o eliminar distorsiones (Vorobioff et al., 2022).

Se observó que el entrenamiento efectivo de estos modelos requiere grandes volúmenes de datos y procesamiento computacional, lo cual constituye un desafío técnico (Caicedo y López, 2017).

También se identificaron riesgos relacionados con las variables ocultas o “confounding factors”, que pueden afectar la capacidad de generalización del modelo, tal como se aborda en el módulo 5 del curso de Stanford (Coursera, 2023).

Finalmente, se encontró que las RNA podrían aplicarse como alternativa al procesamiento iterativo convencional en tomografía, acelerando el proceso de reconstrucción de

imagen y permitiendo una reducción adicional de la dosis de radiación sin comprometer la calidad diagnóstica (Moreno Berdón, 2021).

Resultados Cuantitativos Extraídos de la Literatura Revisada

A partir de la revisión bibliográfica realizada, se identificaron diversos datos relevantes que permiten cuantificar o evidenciar los beneficios y limitaciones del uso de redes neuronales artificiales en el contexto de la tomografía computarizada. Aunque no todos los estudios ofrecen cifras exactas, sí presentan estimaciones cualitativas o resultados visuales que pueden ser útiles para el análisis. Estos hallazgos se resumen en la siguiente tabla para facilitar su comprensión y análisis comparativo

Estudio / Fuente	Tipo de mejora	Indicador cuantitativo	Ventaja principal	Desventaja o limitación
Redes Neuronales en Medicina (2021)	Mejora en precisión diagnóstica	Médico general: 79% → +RNA: 87.1%	Aumento significativo en precisión diagnóstica	Requiere entrenamiento especializado del personal
Vorobioff et al. (2022)	Reducción de artefactos en TC	Reducción de ruido en reconstrucción	Mejora la calidad visual de las imágenes sin aumentar dosis	No detalla cifras exactas ni validación clínica extensa
Moreno Berdón (2021)	Dosis vs calidad	Mantiene calidad diagnóstica con menor dosis	Permite reducir la exposición del paciente a radiación	Requiere gran cantidad de datos y procesamiento computacional
Curso Stanford ML (2023)	Generalización del modelo	Alta sensibilidad a <i>confounding factors</i>	Reconoce la necesidad de transparencia	Alta vulnerabilidad ante

			a en	variables no
			modelos de	controladas
			IA	
			Señala la	Difícil de
		Necesidad de	importancia	aplicar en
Caicedo y López (2017)	Requerimiento	datos	de datos de	entornos con
	s técnicos	masivos y	calidad para	baja
		etiquetados	el	infraestructur
			aprendizaje	a tecnológica
			Demuestra	No ofrece
	Corrección de	Resultados	impacto	datos
Ortiz et al. (2015)	artefactos en	visuales	positivo en	cuantificables
	TC	positivos	calidad de	ni replicación
			imagen	a gran escala
			Resalta la	No aborda
	Rol del	Profesional	importancia	directamente
	profesional en	como filtro	del rol	la integración
García Gallardo et al. (2024)	imágenes	ante errores	humano en	técnica con
	diagnósticas	diagnósticos	validación	modelos
			de imágenes	neuronales
Estudio / Fuente	Tipo de	Indicador	Ventaja	Desventaja o
	mejora	cuantitativo	principal	limitación
Redes Neuronales en Medicina	Mejora en	Médico	Aumento	Requiere
(2021)	precisión	general: 79%	significativo	entrenamient
	diagnóstica			o

		→ +RNA:	en precisión	especializado
		87.1%	diagnóstica	del personal
			Mejora la	
			calidad	No detalla
	Reducción de	Reducción de	visual de las	cifras exactas
	artefactos en	ruido en	imágenes	ni validación
Vorobioff et al. (2022)	TC	reconstrucción	sin	clínica
		n	aumentar	extensa
			dosis	
				Requiere
		Mantiene	Permite	gran cantidad
		calidad	reducir la	de datos y
	Dosis vs	diagnóstica	exposición	procesamiento
Moreno Berdón (2021)	calidad	con menor	del paciente	o
		dosis	a radiación	computacional
				al
			Reconoce la	
			necesidad	Alta
		Alta	de	vulnerabilidad
	Generalización	sensibilidad a	transparencia	d ante
Curso Stanford ML (2023)	del modelo	<i>confounding</i>	a en	variables no
		<i>factors</i>	modelos de	controladas
			IA	
	Requerimiento	Necesidad de	Señala la	Difícil de
Caicedo y López (2017)	s técnicos	datos	importancia	aplicar en

		masivos y etiquetados	de datos de calidad para el aprendizaje	entornos con baja infraestructura tecnológica
Ortiz et al. (2015)	Corrección de artefactos en TC	Resultados visuales positivos	Demuestra impacto positivo en calidad de imagen	No ofrece datos cuantificables ni replicación a gran escala
García Gallardo et al. (2024)	Rol del profesional en imágenes diagnósticas	Profesional como filtro ante errores diagnósticos	Resalta la importancia del rol humano en validación de imágenes	directamente la integración técnica con modelos neuronales

Nota. Se mencionan los diferentes autores que han contribuido con el desarrollo de la tomografía computarizada y los años en que estas fueron realizadas, además se resalta la importancia de tener claridad en cuáles son sus principales ventajas y desventajas.

Limitaciones Encontradas y Aterrizaje al Contexto Nacional

Aunque en la bibliografía revisada no se hace una referencia directa al contexto colombiano o a sus territorios como puntos de análisis, un abordaje sistemático y realista permite identificar debilidades estructurales que enfrenta actualmente el sistema de salud nacional para la implementación de redes neuronales artificiales en tomografía computarizada. Desde el análisis bibliográfico se destacan las siguientes falencias

Interpretabilidad limitada

Las RNA funcionan como sistemas de “caja negra”, en los que no siempre es posible explicar cómo se llegó a un resultado. Esta falta de transparencia, señalada en el curso de Stanford (2023), dificulta su uso clínico en entornos donde es esencial justificar cada decisión diagnóstica.

Dependencia de Datos Masivos

Diversos autores (Caicedo y López, 2017; Vorobioff et al., 2022) advierten que estos modelos requieren grandes volúmenes de datos etiquetados para lograr un entrenamiento efectivo, lo que representa una barrera significativa, especialmente para instituciones que no cuentan con bases clínicas digitalizadas o estructuradas.

Limitada validación clínica

Algunos modelos revisados muestran resultados prometedores en entornos simulados, pero carecen de pruebas de validación en contextos clínicos reales, lo cual impide su implementación directa (Moreno Berdón, 2021).

Altos Requerimientos Tecnológicos

Como se menciona en Matich (2001) y otros autores, las RNA requieren hardware especializado y capacidad de cómputo avanzada, elementos no siempre disponibles en instituciones medianas o rurales.

Aterrizando este análisis al contexto colombiano:

En Colombia, gran parte de las instituciones de salud pública y centros rurales carecen del equipamiento necesario para implementar este tipo de modelos. La falta de bases de datos robustas y estandarizadas también limita el desarrollo de soluciones propias. La mayoría de las propuestas revisadas provienen de entornos altamente tecnificados y con acceso a infraestructura

avanzada, por lo que su adaptación al sistema de salud colombiano requiere inversión, regulación, y acompañamiento desde instituciones académicas y del Estado.

Adicionalmente, se reconoce que la implementación efectiva de redes neuronales en salud requiere de la participación de un equipo multidisciplinario, conformado por profesionales de informática, análisis de datos, medicina, ingeniería biomédica y otras áreas, que actúen como stakeholders en el diseño, entrenamiento y validación de los modelos. Esta colaboración debe estar respaldada por procesos formativos técnicos y tecnológicos que operen al unísono para asegurar la viabilidad clínica y operativa del sistema.

Este enfoque integral es necesario para garantizar que la red neuronal sea viable técnica y clínicamente, lo cual depende en gran medida del acceso a especializaciones técnicas y tecnológicas que trabajen de forma conjunta, especialmente en entornos donde no existen estándares unificados ni marcos regulatorios sólidos.

En conjunto, estos estudios evidencian que las RNA tienen un potencial significativo para sustituir técnicas de posprocesamiento convencional, optimizando tanto la calidad como el tiempo de análisis clínico. Sin embargo, también presentan retos técnicos como la necesidad de hardware especializado y la interpretación limitada de sus resultados, lo cual dificulta su adopción en contextos donde se requiere justificar cada decisión médica.

Finalmente, más allá del desarrollo técnico de las redes neuronales artificiales aplicadas a tomografía computarizada, es indispensable que los profesionales comprendan el funcionamiento de estos modelos, sean capaces de interpretar sus resultados en función del objetivo diagnóstico y del perfil clínico del paciente, y adapten su toma de decisiones en consecuencia. Asimismo, debe contemplarse la necesidad de contar con un aval presupuestal que permita la formalización de estudios, capacitaciones y adquisición de infraestructura. En el contexto colombiano, donde el

desarrollo de tecnologías médicas basadas en inteligencia artificial aún no alcanza el nivel de sus contrapartes internacionales, resulta esencial que las políticas públicas y académicas promuevan la profesionalización técnica del personal, el fortalecimiento institucional y la inversión sostenida. Solo así podrá garantizarse una implementación viable, equitativa y ajustada a las realidades del sistema de salud nacional.

Conclusiones

La aplicación de redes neuronales artificiales en tomografía computarizada constituye una herramienta altamente valiosa en el ámbito del diagnóstico por imágenes. Estas tecnologías permiten optimizar significativamente la calidad visual de las imágenes obtenidas, facilitando una interpretación más clara y precisa por parte del radiólogo. Además, contribuyen de manera efectiva a la reducción de artefactos, lo que mejora la visibilidad de estructuras anatómicas clave, y permiten mantener niveles más bajos de exposición a la radiación, protegiendo así la seguridad del paciente. Todo esto se logra sin comprometer la exactitud diagnóstica, lo que posiciona a las redes neuronales como un apoyo fundamental en la evolución hacia una radiología más eficiente, segura y basada en inteligencia artificial.

Los modelos avanzados basados en aprendizaje profundo como las redes neuronales convolucionales (CNNs), poseen un notable potencial para optimizar los procesos diagnósticos en imagenología. Su capacidad para reconocer patrones complejos y corregir artefactos en las imágenes permite obtener resultados más precisos, lo que se traduce en una mayor confiabilidad de los estudios clínicos. Adicionalmente, estas redes pueden adaptarse a diferentes tipos de datos y modalidades de imagen, automatizando tareas como la detección de anomalías y la clasificación de patologías.

Es importante que el personal en imágenes diagnósticas cuente con formación técnica especializada en redes neuronales, no solo para operar los sistemas, sino también para interpretar los resultados, validar la calidad de la imagen y detectar posibles errores derivados del procesamiento automatizado.

En Colombia, persisten desafíos considerables para la implementación exitosa de tecnologías basadas en redes neuronales en el ámbito diagnóstico, principalmente debido a

limitaciones en infraestructura, presupuesto y formación especializada. Estos obstáculos dificultan la integración efectiva de soluciones avanzadas en los sistemas de salud. Por lo tanto, es crucial contar con el respaldo institucional y gubernamental, que promueva la investigación, la capacitación continua y el desarrollo de soluciones adaptadas a las necesidades y realidades del contexto nacional, garantizando así una transición eficiente hacia una medicina más moderna y accesible.

Es importante fortalecer la formación de equipos multidisciplinarios que combinen expertos en informática, medicina, ingeniería biomédica y análisis de datos, para asegurar una implementación apropiada, ética y adaptada al contexto de las redes neuronales en el sector salud.

Recomendaciones

Promover la capacitación técnica de los profesionales de salud en el uso e interpretación de modelos basados en redes neuronales.

Incentivar el desarrollo de bases de datos colaborativas que permitan el entrenamiento efectivo de modelos RNA en contextos locales.

Implementar protocolos de validación cruzada para garantizar la fiabilidad de las salidas de los modelos antes de su aplicación clínica.

Continuar la investigación interdisciplinaria entre ingeniería y medicina para desarrollar soluciones adaptadas a las necesidades reales del entorno clínico.

Considerar la ética del uso de inteligencia artificial en salud, especialmente en la toma de decisiones diagnósticas automatizadas.

Evaluar el uso de redes neuronales como alternativa o complemento a las técnicas de procesamiento iterativo en tomografía, con el fin de mejorar la eficiencia clínica y la seguridad del paciente.

Es necesario avanzar en técnicas de explicabilidad en inteligencia artificial para superar el problema de la "caja negra" en redes neuronales, especialmente en aplicaciones clínicas donde la comprensión del proceso diagnóstico es esencial.

Es fundamental evaluar la viabilidad (feasibility) antes de desarrollar e implementar redes neuronales artificiales en tomografía computarizada u otras aplicaciones médicas. Esto implica analizar si la solución realmente responde a una necesidad significativa, si el costo y el esfuerzo de desarrollo están justificados por los beneficios potenciales, y si la herramienta será práctica y efectiva en su entorno de uso. Además, se debe garantizar un monitoreo constante de los resultados y del entrenamiento de estas redes para identificar posibles limitaciones o

inconsistencias, asegurando que la inversión tenga un impacto tangible y positivo en la práctica clínica.

Referencias Bibliográficas

- Acosta, J., & Soria, A. (2015). *Tomografía computarizada dirigida a técnicos superiores en imagen para el diagnóstico*.
- Basogain Olabe, X. (s.f.). *Redes Neuronales Artificiales y sus Aplicaciones*. Escuela Superior de Ingeniería de Bilbao, EHU.
https://ocw.ehu.eus/pluginfile.php/40137/mod_resource/content/1/redes_neuro/contenidos/pdf/libro-del-curso.pdf
- Calzado, A., & Geleijns, J. (2010). Computed Tomography. Evolution, technical principles and applications. *Revistadefisicamedica.es*.
<https://revistadefisicamedica.es/index.php/rfm/article/download/115/115>
- Cruz Serrano, E. M. (2022). Artefactos frecuentes en TAC. *Ocronos*, 5(2), 34.
<https://revistamedica.com/artefactos-frecuentes-tac/>
- Lagares, R., Del Mar García Gallardo, M., Rodríguez, A. M., Lagares, R. M., & Castro, A. A. (2024). Artefactos en resonancia magnética. Reconocerlos lo antes posible para eliminarlos. *Seram*, 1(1). https://piper.espacio-seram.com/index.php/seram/article/view/9803?utm_source=chatgpt.com
- Lungren, M., & Yeung, S. (s.f.). *Fundamentals of Machine Learning for Healthcare*. Coursera.
<https://www.coursera.org/learn/fundamental-machine-learning-healthcare>
- Martín Cuartero, J., Quintana Martínez, I., Elvira Dinu, L., González Gambau, J., Gómez Gil, T., & Artigas Martín, J. M. (2018). "Eppur si muove". Artefactos por movimiento en TC. Conocerlos y evitarlos.
- Matich, D. J. (2001). Redes Neuronales: Conceptos básicos y aplicaciones. *Universidad Tecnológica Nacional, México*, 41, 12-16.

McCulloch, W. S., y Pitts, W. (1943). Un cálculo lógico de las ideas immanentes en la actividad nerviosa. *Boletín de Biofísica Matemática*, 5, 115-133.

<https://doi.org/10.1007/BF02478259>

Ortiz, P., Sartori, P., & Griensu, A. (2015). Artefactos y artificios frecuentes en tomografía computada y resonancia magnética. *Revista Argentina de Radiología*, 79(4), 238-246.

https://www.elsevier.es/es-revista-revista-argentina-radiologia-383-articulo-artefactos-artificios-frecuentes-tomografia-computada-S0048761915000794?utm_source=chatgpt.com

Red Neuronales Artificiales en la Medicina. (2021). *Octavo Congreso Nacional de Ingeniería Informática/Sistemas de Información*. Buenos Aires: Universidad Tecnológica Nacional.

https://grupogemis.com.ar/wp-content/uploads/2021/11/RNA_Medicina.pdf

Redes neuronales artificiales. ingenio y conciencia: boletín. (s.f.). *Ingenio y conciencia: boletín científico de la Escuela Superior de Ciudad Sahagún*, 2(4).

<https://repository.uaeh.edu.mx/revistas/index.php/sahagun/article/view/14132>

Romero, L. A., y Calonge Cano, T. (s.f.). *Redes Neuronales y Reconocimiento de Patrones*.

Departamento de Informática y Automática, Universidad de Salamanca y Departamento de Informática, Universidad de Valladolid. España.

https://gredos.usal.es/bitstream/handle/10366/21694/dia_redes_neuronales.pdf?sequence=1

Seeram, E. (2016). *Tomografía computarizada: Principios físicos, aplicaciones clínicas y control de calidad*. (4^a ed.). Elsevier.

Verino, C., et al. (2020). Redes Neuronales. *Octavo Congreso Nacional de Ingeniería Informática*. <https://grupogemis.com>